

ГОРНОПРОМЫШЛЕННАЯ И НЕФТЕГАЗОПРОМЫСЛОВАЯ ГЕОЛОГИЯ,
ГЕОФИЗИКА, МАРКШЕЙДЕРСКОЕ ДЕЛО И ГЕОМЕТРИЯ НЕДР

Научная статья

УДК 622.012.3; 303.717

<https://elibrary.ru/qkftpf><https://doi.org/10.21285/2686-9993-2023-46-2-212-225>**Адаптивный интеллектуальный анализ данных
как инструмент для прогнозирования ресурса
узлов горных машин и оборудования****В.А. Храмовских^а, А.Н. Шевченко^б, К.А. Непомнящих^с**^{а-с}*Иркутский национальный исследовательский технический университет, г. Иркутск, Россия*

Резюме. В современном мире горнодобывающая промышленность является одной из наиболее важных отраслей экономики. Сложные условия работы, высокие нагрузки и необходимость постоянного контроля за техническим состоянием оборудования требуют высокой квалификации специалистов и эффективных инструментов для анализа большого объема данных. Анализ отказов горных машин и оборудования, в свою очередь, является одним из важных процессов для определения и устранения причин отказов с целью повышения надежности и безопасности работы машин и оборудования. Использование современных методов статистической обработки данных позволяет сделать этот процесс более эффективным и точным. Разработка инструмента для анализа отказов горных машин и оборудования может принести значительные выгоды горнодобывающим компаниям. Анализируя данные об отказах оборудования, выявляя первопричины и предоставляя рекомендации по корректирующим действиям, инструмент анализа может помочь предотвратить отказы оборудования, повысить безопасность и производительность. Разработка этого инструмента требует междисциплинарного подхода и должна быть построена таким образом, чтобы быть удобной для пользователя и масштабируемой. В связи с этим целью исследования стало представление способа создания адаптивного инструмента для анализа отказов горных машин на базе программы Microsoft Excel. Авторами рассмотрены основные принципы работы данного инструмента, его функциональный состав и возможности использования при различных условиях эксплуатации горной техники. Значительное внимание уделено описанию основного алгоритма работы программы, который позволяет эффективно обрабатывать большие объемы данных, выдавать точные результаты и отображать их в удобном виде с целью оценки уровня надежности и перехода к прогнозированию ресурса узлов горных машин и оборудования. Дальнейшее улучшение инструмента адаптивного анализа данных о работе горных машин в рамках данного исследования может быть осуществлено путем добавления новых параметров или автоматизации процессов поиска причин отказов с использованием нейросетей.

Ключевые слова: надежность оборудования, остаточный ресурс, анализ отказов, прогнозирование, нейронные сети

Для цитирования: Храмовских В.А., Шевченко А.Н., Непомнящих К.А. Адаптивный интеллектуальный анализ данных как инструмент для прогнозирования ресурса узлов горных машин и оборудования // Науки о Земле и недропользование. 2023. Т. 46. № 2. С. 212–225. <https://elibrary.ru/qkftpf>, <https://doi.org/10.21285/2686-9993-2023-46-2-212-225>.

APPLIED MINING AND PETROLEUM FIELD GEOLOGY,
GEOPHYSICS, MINE SURVEYING AND SUBSOIL GEOMETRY

Original article

**Adaptive data mining as a tool to predict
mining machinery and equipment assembly life****Vitaliy A. Khramovskikh^а, Aleksey N. Shevchenko^б, Kirill A. Nepomnyashchikh^с**^{а-с}*Irkutsk National Research Technical University, Irkutsk, Russia*

© Храмовских В.А., Шевченко А.Н., Непомнящих К.А., 2023



Abstract. Mining industry is one of the most important economic sectors in the modern world. Complex working conditions, high loads and the need for continuous monitoring of equipment technical condition require highly qualified specialists and effective tools to analyze large data volumes. Failure analysis of mining machinery and equipment is one of the important processes to determine and eliminate the causes of failures in order to improve the reliability and safety of machinery and equipment operation. The use of modern methods of statistical data processing makes this process more efficient and accurate. The development of a tool for failure analysis of mining machines and equipment can be very beneficial to mining companies. By analyzing the data on mining machines and equipment failures, identifying the primary causes of failures and providing corrective recommendations, the analysis tool can prevent equipment failures, improve machine safety and performance. The development of this tool requires an interdisciplinary approach as it should be user-friendly and scalable. In this regard, the purpose of the study is to present a creation method of an adaptive tool for the Microsoft Excel-based analysis of mining machine failures. The authors consider the basic operation principles of this tool, its functional composition and application potential under various operating conditions of mining equipment. Much attention is paid to the description of the main operation algorithm of the program, which makes it possible to efficiently process large volumes of data, produce accurate results and display them in the form convenient for reliability level estimation and transition to the forecasting of mining machinery and equipment assembly life. Further improvement of the tool for adaptive analysis of data on mining machine operation, within the framework of this study, can be performed by adding new parameters or automation of the troubleshooting processes using neural networks.

Keywords: equipment reliability, residual resource, failure analysis, forecasting, neural networks

For citation: Khramovskikh V.A., Shevchenko A.N., Nepomnyashchikh K.A. Adaptive data mining as a tool to predict mining machinery and equipment assembly life. *Nauki o Zemle i nedropol'zovanie = Earth sciences and subsoil use*. 2023;46(2):212-225. (In Russ.). <https://elibrary.ru/qkftpf>, <https://doi.org/10.21285/2686-9993-2023-46-2-212-225>.

Введение

От технического состояния горных машин зависит производительность и объемы добычи полезных ископаемых, поэтому важно обладать адаптивным инструментом оперативного контроля текущего технического состояния основного и вспомогательного технологического оборудования. Оценку уровня надежности работы горнодобывающих машин в процессе их эксплуатации производят на основании статистических данных [1–3]. В связи с этим остро встает вопрос поиска инструмента для выявления статистических закономерностей возникновения отказов элементов горных машин и оборудования с учетом конкретных режимов эксплуатации и внешних условий. Сбор, обработка и анализ статистической информации об отказах, то есть формирование базы данных, является отправной точкой для установления закономерностей их возникновения, что позволяет произвести классификацию причин отказов по следующим категориям: основные системы горных машин и оборудования, хронология событий, наработка углов и агрегатов, а также другим критериям. Использование результатов анализа открывает возможность перехода к прогнозированию основных показателей уровня надежности горных машин и оборудования, таких как коэффициент технической готовности (КТГ), коэффициент технического исполь-

зования (КИО), наработка на отказ (MTBF), среднее время восстановления (MTTR) и другие. Внедрение предлагаемого адаптивного инструмента на горнодобывающих предприятиях позволит принимать взвешенные решения при планировании горных работ, оптимизировать принятую систему технического обслуживания и ремонта, прогнозировать риски возникновения неблагоприятных событий, а также оптимизировать внутренние бизнес-процессы для обеспечения устойчивого развития предприятий, столь актуальные при проведении перехода к цифровой трансформации горнодобывающей отрасли [4–6].

Материалы и методы исследования

Процедура анализа отказов горных машин и оборудования представляет собой системный подход к изучению неисправностей машин и оборудования, а также причин их возникновения. Эта процедура позволяет выявлять и анализировать основные причины отказов, чтобы разрабатывать эффективные меры по их предотвращению. Процедура анализа отказов горных машин включает несколько этапов.

Первым шагом процедуры анализа отказов горных машин является сбор данных. Необходимо собрать данные о техническом состоянии оборудования и обработать их для



последующего анализа. Сбор данных может включать следующие источники информации: журналы обслуживания, данные мониторинга, отчеты операторов и т. д.

Вторым шагом становится классификация отказов. Она позволяет выявить основные типы отказов и разделить их на группы. Для каждого типа отказов можно разработать соответствующие меры по предотвращению этих отказов в будущем.

После классификации отказов необходимо провести анализ причин отказов. Для этого необходимо провести тщательное исследование и установить, какие факторы привели к отказу оборудования. При этом могут использоваться различные методы, такие как метод дерева отказов, метод причинно-следственной диаграммы (диаграммы Исикавы), факторный анализ и т. д.

На основе результатов анализа причин отказов можно разработать меры по предотвращению этих отказов в будущем. Эти меры могут включать улучшение процедур обслуживания, замену деталей и компонентов, обучение персонала и т. д.

Последний шаг – оценка эффективности мер. Необходимо проанализировать эффективность принятых мер по предотвращению отказов. Это поможет определить, какие меры были наиболее эффективными, а также какие изменения необходимо внести в процедуру анализа отказов, чтобы улучшить ее.

Из вышеизложенных этапов следует, что для математической обработки полученных данных сначала необходимо их накопление и систематизация.

При проведении первого этапа – сбора данных – основными целями накопления информации об отказах являются:

- накопление материалов, необходимых для определения и уточнения значений показателей надежности;
- оценка и прогнозирование технико-экономических показателей работы машин с учетом уровня их надежности;
- изучение влияния условий и особенностей эксплуатации на надежность и выработку машин;

– разработка мероприятий по устранению конструктивных, технологических и других недостатков машин при их проектировании и изготовлении;

– накопление сведений, необходимых для установления норм расхода запасных частей, ремонтных нормативов и совершенствования системы ремонтов;

– разработка имитационных моделей эксплуатации машин для совершенствования методов их технической эксплуатации и организации работы обслуживающего персонала;

– уточнение технической документации;

– разработка справочно-информационного и программного обеспечения автоматизированного рабочего места механика (например, «АРМ механика») горного предприятия [7].

Для сбора статистической информации об отказах и фактическом техническом состоянии горных машин и оборудования на предприятиях используются различные источники и способы:

– бумажные бортовые журналы (эффективный, но уже устаревший способ ведения статистики отказов, поскольку требует выполнения дополнительных операций по переносу данных в электронный формат для последующей оперативной оценки);

– электронные таблицы (журналы) (этот способ сбора информации обладает недостаточной наглядностью и требует ручного труда по заполнению таблиц);

– специализированное программное обеспечение по типу системы SAP Plant Maintenance (SAP PM).

Система SAP PM имеет ряд модулей, которые позволяют обеспечивать управление техническими объектами и основным оборудованием, планирование технического обслуживания, управление уведомлениями о рабочих процессах и рабочими заказами в рамках управления заказами на обслуживание, сбор статистики об отказах. SAP PM¹ является очень эффективным инструментом для централизованного планирования технического обслуживания, который управляет всеми операциями по техническому обслуживанию в организации. К недостаткам применения SAP

¹ SAP PM – краткое руководство // CoderLessons.com. [Электронный ресурс]. URL: <https://coderlessons.com/tutorials/sap/uznaite-sap-pm/sap-pm-kratkoe-rukovodstvo> (28.04.2023).



следует отнести значительную величину затрат на приобретение данного иностранного программного обеспечения.

Модуль технического обслуживания состоит из ключевых действий, которые включают проверку, уведомления, корректирующее и профилактическое обслуживание, ремонт и другие меры по поддержанию оптимальной технической системы.

Прикладной компонент SAP PM предоставляет организации инструмент для выполнения основных технологических операций по техническому обслуживанию. Все действия, выполняемые в рамках технического обслуживания, взаимосвязаны, и поэтому этот модуль тесно интегрирован с другими модулями – планирования производства, управления материалами, продаж и т. д. Используя SAP PM, можно выполнять автоматизацию планирования ремонтных работ и упрощать работу по техническому обслуживанию и ремонту на предприятии. Система позволяет документировать существующие проблемы, планировать трудовые и материальные ресурсы, контролировать их расход с целью эффективного управления корпоративными активами.

Для выполнения технического обслуживания и ремонта система содержит следующие подмодули: управление техническими объектами, планирование задачи технического обслуживания, управление уведомлениями о рабочем процессе и заказами на выполнение работ.

Рассмотренные выше способы имеют существенный недостаток, заключающийся в слабой визуализации анализируемых данных, которая затрудняет проведение оперативного анализа технического состояния горных машин и оборудования.

Использование такого инструмента, как дашборд (*от англ.*: dashboard), для анализа отказов горных машин и оборудования может значительно упростить процесс анализа данных и повысить эффективность принимаемых решений. Дашборды – это специальные инструменты для визуализации данных, которые позволяют отображать ключевые показатели производительности, состояние оборудования, данные о производственных операциях и т. д. на одном экране. Для создания

дашборда необходимо выбрать подходящую платформу и определить ключевые показатели работы машины, которые будут отображаться на дисплее. Некоторые платформы предлагают для анализа отказов горных машин и оборудования готовые шаблоны дашбордов, которые можно настроить в соответствии с конкретными потребностями предприятия.

Дашборд может отображать множество данных, таких как:

- состояние оборудования: все показатели могут отражаться в виде графиков или диаграмм, отображающих основные показатели надежности горных машин и оборудования, количество отказов оборудования, коэффициент технического использования, фактическое техническое состояние и т. д.);

- производительность: данные о производительности можно отображать в виде графиков, диаграмм или таблиц, показывающих объемы добычи горной массы, количество отработанных моточасов и т. д.);

- расходы на обслуживание и ремонт: данные о расходах на обслуживание и ремонт могут быть отображены в виде диаграмм или таблиц, показывающих, какие затраты были сделаны на обслуживание и ремонт каждой единицы оборудования);

- данные о персонале: данные о персонале могут быть отображены на дашборде в виде графиков или таблиц, показывающих количество персонала на каждом объекте, его квалификацию и т. д.

Процедура обработки данных об отказах горных машин с применением такого инструмента, как дашборд, возможна при использовании программы Microsoft Excel. Пример подобного использования приведен ниже и включает в себя несколько этапов:

1. Импорт данных. Сначала необходимо импортировать данные об отказах горных машин и оборудования в программу Microsoft Excel. Для этого можно использовать различные форматы файлов, например CSV, TXT или XLSX.

2. Очистка и форматирование данных. После импорта данных необходимо провести их очистку и форматирование, чтобы данные были однородными и соответствовали требу-



емому формату. Это может включать удаление пустых ячеек, корректировку ошибок в данных и приведение данных к необходимому формату.

3. Создание таблицы данных. После очистки и форматирования данных необходимо создать таблицу данных, которая будет использоваться для создания дашборда. В таблице должны быть указаны ключевые параметры, такие как наименование оборудования, тип отказа, дата и время отказа и прочие параметры, которые могут быть полезны для анализа.

4. Создание графиков и диаграмм. После создания таблицы данных можно перейти к созданию графиков и диаграмм на основе этих данных. Например, можно создать график, отображающий количество отказов по дням недели, или диаграмму, показывающую распределение отказов по типу оборудования.

5. Создание дашборда. После создания графиков и диаграмм можно начать создание дашборда, который будет отображать ключевые показатели производительности и состояние оборудования. Для этого можно использовать различные инструменты Microsoft Excel, такие как графики, таблицы и диаграммы.

6. Настройка параметров дашборда. После создания дашборда необходимо настроить его параметры, такие как цвета, шрифты и размеры элементов. Также можно добавить различные функции, например фильтры и сортировки, для более удобной работы с данными.

7. Анализ данных. После создания и настройки дашборда можно приступить к анализу данных. На основе дашборда можно проводить анализ состояния оборудования, производительности и затрат на обслуживание и ремонт. Также можно использовать дашборд для прогнозирования возможных отказов и предлагать рекомендации по улучшению процессов обслуживания и ремонта.

Использование дашбордов может значительно повысить эффективность анализа данных и сократить время на принятие решений для предотвращения отказов. Учитывая ограничения дашбордов по объему обрабатываемой информации и применяемым механизмам выявления неявных закономерностей, вероятным способом обработки большого массива данных с элементами предик-

тивной аналитики могут являться нейронные сети.

Для решения этой задачи можно использовать успешные кейсы, реализованные в различных областях машиностроения, основанные на таких инструментах и библиотеках, как Python, Pandas, NumPy, Scikit-learn, TensorFlow, Keras, PySerial для считывания данных с COM-порта и т. д. [8–11].

Нейронные сети как вычислительные системы, созданные для моделирования аналитических действий при обработке больших массивов данных, позволяют осуществлять анализ и поиск взаимосвязи между большим количеством переменных. Этот инструмент может эффективно обучаться, учитывая закономерности существующих показателей в работе горных машин, и примеры использования такого способа во многих областях жизнедеятельности человека широко известны.

В машиностроении используются нейросети для диагностики неисправностей такого оборудования, как насосы, турбины и компрессоры, которое является важным компонентом во многих промышленных процессах. Эти машины подвержены различным типам неисправностей, среди которых выделяются несоосность, износ подшипников и дисбаланс. Анализ сложных и зашумленных данных о вибрации может являться невыполнимой задачей для человека, в то же время для автоматического выявления неисправностей в данных о вибрации может быть использована адаптированная обучением нейронная сеть. В качестве входных данных для нейронной сети могут использоваться данные о вибрации, а в качестве выходных – данные о вероятности неисправности машины для прогнозирования ресурса оборудования. Такой подход имеет ряд преимуществ по сравнению с традиционными методами обнаружения неисправностей: это быстрота, точность и возможность обнаруживать неисправности на ранней стадии, что может предотвратить катастрофические сбои и сократить время простоя в ремонте. Кроме того, нейронная сеть может учиться на собственном опыте, что означает, что со временем она может улучшить свою производительность [12–15].

В целом использование нейронных сетей в машиностроении имеет потенциал для по-



вышения точности и эффективности различных задач, таких как диагностика неисправностей, оптимизация конструкции и прогнозируемое техническое обслуживание.

Одним из примеров использования нейросетей в горнодобывающей промышленности является применение искусственных нейронных сетей для предсказания отказов горных машин и оборудования. Этот метод анализа больших объемов данных об отказах горных машин и оборудования позволяет предотвратить неожиданные отказы и снизить время простоя оборудования, что существенно влияет на эффективность работы всего производственного процесса.

Для обучения нейросети необходимо подготовить большой набор исходных данных, содержащий информацию о параметрах работы машин и оборудования, а также данные об отказах и их причинах. Данные могут быть собраны путем мониторинга работы оборудования и анализа журналов обслуживания. После подготовки набора данных искусственная нейронная сеть обучается на основе примеров и находит взаимосвязи между показателями работы машин и оборудования и вероятностью отказов. Нейросеть может предсказывать вероятность отказа на основе ранее полученных данных, текущих показателей работы машин и оборудования, данных о различных переменных, которые могут коррелировать с отказом, таких как температура, влажность или вибрация и другие, на основе изучения закономерности и взаимосвязи, которые можно использовать для прогнозирования будущих отказов [16–18].

Для успешного решения поставленной задачи по аналогии с известными решениями, описанными во многих источниках, работа программы должна состоять из следующих шагов:

- сбор и подготовка данных: сбор данных с датчиков машины и сохранение их в файле CSV, загрузка данных в Python с помощью библиотеки Pandas, очистка и предварительная обработка данных (например, удаление нулевых значений, выбросов и пропущенных данных);

- разделение данных на обучающую и тестовую выборки: обучающая выборка будет использоваться для тренировки модели, а тестовая – для проверки ее качества;

- обучение модели машинного обучения: на этапе обучения модели машинного обучения необходимо определить, какие переменные (измерения) влияют на неисправности и как они связаны друг с другом; данный шаг также подразумевает использование алгоритмов машинного обучения, таких как регрессия или классификация, для обучения модели на обучающей выборке (например, можно использовать модель линейной регрессии для предсказания показателя в будущем на основе текущих измерений датчиков);

- оценка качества модели: оценка качества модели на тестовой выборке с использованием метрики, такой как R-квадрат или среднеквадратичная ошибка;

- обработка данных: для анализа и обработки данных можно использовать различные методы, включая средства статистического анализа, машинного обучения, графического анализа и т. д.;

- использование модели для предсказания: когда модель обучена и протестирована, можно использовать ее для предсказания неисправностей на основе изменений температуры или других параметров, измеряемых датчиками на горной машине.

В целом эффективность использования нейронных сетей для прогнозирования отказов зависит от качества и количества имеющихся данных, а также от сложности изучаемой системы. Тем не менее при правильном подходе и достаточном количестве данных нейронные сети могут стать мощным инструментом для прогнозирования отказов и улучшения стратегий технического обслуживания. Таким образом, использование искусственных нейронных сетей в горнодобывающей промышленности позволит повысить эффективность работы оборудования и снизить вероятность отказов, что, в свою очередь, существенно повлияет на экономические показатели предприятия [19–21].

На основании данных об отказах основного горнотранспортного оборудования, предоставленных компанией «Полюс Вернинское», сотрудниками кафедры горных машин и электромеханических систем Иркутского национального исследовательского технического университета был произведен анализ важнейших показателей надежности работы машин.



Исходная информация содержала данные машинных отчетов о виде и моделях единиц горного оборудования, дате и времени наступления события, продолжительности ремонтного воздействия, а также описательную часть события, повлекшего остановку оборудования, с указанием причин и конкретных объектов, у которых обнаружен дефект. Исследователями был произведен анализ информации с целью выявления основных причин неисправностей горного оборудования. С учетом того, что исходные данные имеют избыточное количество информации, что, безусловно, является дополнительной проблемой для исследования, предварительно весь объем исходных данных необходимо подвергнуть фильтрации с целью удаления излишнего шума. В ряде случаев представленная информация, напротив, не имеет полноты данных для классификации и установления истинных причин отказа. Так, к примеру, информация о поломках карьерных экскаваторов за один год наблюдения имела порядка 18 % данных с неустановленными причинами поломки.

Инструмент анализа сообщений отказов журнала A2 из системы SAP позволяет оперативно выделять параметры работы машин, опираясь на разнообразные фильтры отбора, в том числе временные (за любой промежуток времени, по которому существует ведомость отказов), фильтры, основанные на наименовании класса единиц оборудования (с детализацией позиции единиц техники и их индивидуальных номеров), фильтры, указывающие

систему или характерную причину, ставшую основанием для остановки, и другие.

Использованный инструмент дашборд позволяет визуализировать отбор данных по конкретным узлам и агрегатам, описательным причинам возникновения отказов и прочим настраиваемым пользователем фильтрам с целью оценки причины отказов и продолжительности простоев для всех единиц горного оборудования предприятия. Имеется возможность вывода и сравнения информации использования оборудования за различные годы, построения линии тренда в одном информационном окне, что дает наглядную картину использования ресурса горными машинами и оборудованием.

Результаты исследования и их обсуждение

В ходе анализа надежности карьерных автосамосвалов компании «Полус Вернинское» был разработан дашборд, который помог оперативно оценить основные показатели надежности, а также составить перечень основных систем и узлов, в которых чаще всего происходят неисправности, с указанием их причин.

Разработанный дашборд позволяет оперативно отфильтровать информацию об интересующей единице техники и построить топ по показателю количества отказов, продолжительности простоя для конкретной модели самосвала за определенный временной промежуток (рис. 1).




Рис. 1. Информационное окно дашборда с указанием распределения отказов по модели карьерных автосамосвалов

Fig. 1. Dashboard information window indicating failure distribution according to the mining dumper model



Также при помощи дашборда можно быстро проанализировать информацию о работе основных систем горнотранспортного оборудования, в которых наиболее часто можно ожидать возникновения неисправности (рис. 2). Судя по информации с дашборда, для карьерных автосамосвалов Komatsu HD1500-8 топ систем, в которых происходит наибольшее количество отказов, возглавляет двигатель внутреннего сгорания, топливная система и ходовая часть. Эта информация может обновляться как в табличном, так и в графическом виде и наглядно демонстрировать изменение в работе техники. При помощи заложенных в программу фильтров легко настроить такие важные показатели, как коэффициент использования оборудования во времени, продолжительность простоев, наработка на отказ, определить некоторые экономические показатели, вывести графическую информацию о единицах техники по критерию лучший / худший и т. д.

На основе информации об отказах с помощью дашборда можно помимо прочего рассчитывать показатели надежности, такие как коэффициент готовности, среднее время восстановления, наработка на отказ и др. (рис. 3), и осуществлять контроль за критическими показателями, сравнивая реальные значения

с плановыми, а также делая необходимые выводы, вносить необходимые изменения в структуру технического обслуживания и ремонта.

Проанализировав с помощью дашборда отказы автосамосвалов Komatsu HD1500-8 за промежуток в два года, можно сделать следующие заключения:

- основными системами, в которых встречаются неисправности, являются: ДВС – 17 %, топливная система – 16 %, ходовая часть – 14 %, электрооборудование – 11 %;

- основными причинами отказа являются организационные причины, которые составляют 51 % от общего числа причин (рис. 4);

- динамика распределения отказов и продолжительности простоя (рис. 5) наглядно иллюстрирует, что пик отказов и продолжительности простоя приходится на летний период с июня по сентябрь.

Использование такого инструмента, как дашборд, дает возможность и руководителям, и сотрудникам инженерного звена, занимающимся эксплуатацией оборудования, наблюдать в режиме реального времени за основными характеристиками работы горнотранспортного оборудования с целью управления плановыми показателями. С помощью этого инструмента легко перейти к определению и оценке наиболее подверженных неисправно-



Рис. 2. Информационное окно дашборда с указанием распределения отказов по системам карьерных автосамосвалов HD1500-8

Fig. 2. Dashboard information window indicating failure distribution according to the HD1500-8 mining dumper systems




Рис. 3. Информационное окно дашборда с показателями надежности конкретного карьерного автосамосвала HD1500-8
Fig. 3. Dashboard information window indicating reliability indicators of a specific HD1500-8 mining dumper

стям узлов горных машин и оборудования и более детально разобраться в коренных причинах возникновения неисправностей.

Учитывая большой объем исходных данных и возможность их визуализации, появляется перспектива создания модели системы оценки карты дефектов, которая в итоге должна повлиять на изменение стратегии обслуживания горного оборудования с целью снижения стоимости ремонтов и рационального обоснования количества запасных частей. Исходя из накопленной информации, авторам статьи видится дальнейшая перспектива в использовании исходных данных совместно или посредством обработки их массива нейронными сетями с целью возможной предиктивной аналитики с выходом на прогнозирование вероятных отказов элементов горных машин. Существует возможность обработки данных с помощью алгоритмов машинного обучения для предсказания неисправностей на основе показаний контрольных датчиков, установленных непосредственно на горной машине [22–24].

Заключение

Повышение показателей надежности горнодобывающих машин является одной из ос-

новных проблем для компаний, работающих в этой отрасли. Важнейшей частью обеспечения эффективности работы горных машин и оборудования является возможность точного анализа любых потенциальных отказов и их отслеживание во времени. Для этого предприятия должны использовать адаптивные инструменты обработки и анализа данных. В последние годы наблюдается значительное развитие технологии приборных панелей, таких как дашборд, которая помогает горнодобывающим компаниям проводить именно подобный анализ. С помощью приборных панелей сотрудникам стало как никогда легко отслеживать различные аспекты, связанные с отказами оборудования, такие как типы отказов, частота их появления, принадлежность вышедшего из строя узла к той или иной системе машины, а также другую информацию, имеющую отношение к работе оборудования. Все эти данные можно фильтровать и сортировать, чтобы сотрудники, эксплуатирующие горную технику, могли быстро выявить закономерности или определить, какие узлы и системы машины требуют пристального внимания или оперативного вмешательства. Дашборды также предоставляют подробную статистическую информацию о работе оборудо-




Рис. 4. Распределение отказов по причинам их возникновения
Fig. 4. Failure distribution by their occurrence causes




Рис. 5. Динамика распределения отказов по месяцам:
1 – количество отказов; 2 – продолжительность простоя, ч; 3 – тренд количества отказов
Fig. 5. Failure distribution dynamics by months:
1 – number of failures; 2 – idle time, hr; 3 – failure number trend



вания, отражая ключевые показатели эффективности: среднее время между отказами, среднее время восстановления и т. д. Эта информация может быть использована предприятиями при принятии решений об инвестициях в новое оборудование, модернизацию существующего оборудования или о корректировке графиков ремонта и технического обслуживания эксплуатируемых горных машин.

Кроме того, использование приборных панелей значительно облегчает визуализацию тенденций и наблюдение за их изменением во времени. Также оно позволяет компаниям получить доступ ко всей необходимой информации, даже если они не обладают специфическими техническими знаниями, поскольку все операции происходят в самом интерфейсе приборной панели, что значительно упрощает

доступ по сравнению с традиционными методами, такими как электронные таблицы, которые требуют от пользователей определенных навыков, например владения техникой работы с электронными таблицами, понимания сложных формул и т. д. [25, 26]. Это упрощение означает, что даже небольшие компании, не владеющие специализированными отделами, теперь имеют доступ к инструментам анализа, использование которых ранее было доступно только при помощи аутсорсинговых услуг, дорогостоящих программных пакетов, требующих значительных технических знаний, и т. д. В результате не только экономятся деньги, но и повышается общая эффективность организаций, что означает возможные выгоды как с операционной точки зрения, так и с точки зрения экономии средств и т. д.

Список источников

1. Odeyar P., Apel D.B., Hall R., Zon B., Skrzypkowski K. A review of reliability and fault analysis methods for heavy equipment and their components used in mining // *Energies*. 2022. Vol. 15. Iss. 17. P. 6263. <https://doi.org/10.3390/en15176263>.
2. Махно Д.Е., Шадрин А.И. Управление ресурсами технической эксплуатации горного оборудования // *Вестник Иркутского государственного технического университета*. 2005. № 2. С. 68–71. <https://elibrary.ru/jxhoeor>.
3. Храмовских В.А. Оценка ресурса базовых узлов металлоконструкций карьерных экскаваторов на основе обработки статистической информации // *Вестник Иркутского государственного технического университета*. 2005. № 1. С. 167. <https://elibrary.ru/jxklbf>.
4. Zheng S., Cheng K., Wang J., Liao Q., Liu X., Liu W. Failure analysis of frame crack on a wide-body mining dump truck // *Engineering Failure Analysis*. 2015. Vol. 48. P. 153–165. <https://doi.org/10.1016/j.engfailanal.2014.11.013>.
5. Benjumea D.C., Laniado H., Combata O. Analytical model to monitor the oil conditions on the main components of mining dumpers // *Results in Engineering*. 2023. Vol. 17. P. 100934. <https://doi.org/10.1016/j.rineng.2023.100934>.
6. Petrović D.V., Tanasijević M., Stojadinović S., Ivaz J., Stojković P. Fuzzy expert analysis of the severity of mining machinery failure // *Applied Soft Computing*. 2020. Vol. 94. P. 106459. <https://doi.org/10.1016/j.asoc.2020.106459>.
7. Непомнящих К.А. Методика оценки надежности горных машин на эксплуатационной стадии жизненного цикла // *Приоритеты мировой науки: новые подходы и актуальные исследования: сб. науч. тр. по материалам XXIX Междунар. науч.-практ. конф. (г. Анапа, 30 мая 2022 г.)*. Анапа: Изд-во ООО «Научно-исследовательский центр экономических и социальных процессов» в Южном Федеральном округе, 2022. С. 142–150. <https://elibrary.ru/ngpmef>.
8. Awan M.B., Li K., Li Z., Ma Z. A data driven performance assessment strategy for centralized chiller systems using data mining techniques and domain knowledge // *Journal of Building Engineering*. 2021. Vol. 41. P. 102751. <https://doi.org/10.1016/j.jobe.2021.102751>.
9. Arjun S., Murthy L.R.D., Biswas P. Interactive sensor dashboard for smart manufacturing // *Procedia Computer Science*. 2022. Vol. 200. P. 49–61. <https://doi.org/10.1016/j.procs.2022.01.204>.
10. Dogan A., Birant D., Machine learning and data mining in manufacturing // *Expert Systems with Applications*. 2021. Vol. 166. P. 114060. <https://doi.org/10.1016/j.eswa.2020.114060>.
11. Lu Y.-J., Lee W.-C., Wang C.-H. Using data mining technology to explore causes of inaccurate reliability data and suggestions for maintenance management // *Journal of Loss Prevention in the Process Industries*. 2023. Vol. 83. P. 105063. <https://doi.org/10.1016/j.jlp.2023.105063>.
12. Alamdari S., Basiri M.H., Mousavi A., Soofastaei A. Application of machine learning techniques to predict haul truck fuel consumption in open-pit mines // *Journal of Mining and Environment*. 2022. Vol. 13. Iss. 1. P. 69–85. <https://doi.org/10.22044/jme.2022.11577.2145>.
13. Singh K., Maiti J., A novel data mining approach for analysis of accident paths and performance assessment of risk control systems // *Reliability Engineering & System Safety*. 2020. Vol. 202. P. 107041. <https://doi.org/10.1016/j.res.2020.107041>.
14. Wang Z., Xia H., Zhang J., Yang B., Yin W. Imbalanced sample fault diagnosis method for rotating machinery in nuclear power plants based on deep convolutional conditional generative adversarial network // *Nuclear Engineering and Technology*. 2023. Vol. 55. Iss. 6. P. 2096–2106. <https://doi.org/10.1016/j.net.2023.02.036>.
15. Szymahski Z., Paraszczak J. Application of artificial intelligence methods in diagnostics of mining machinery // *IFAC Proceedings Volumes*. 2007. Vol. 40. Iss. 11. P. 403–408. <https://doi.org/10.3182/20070821-3-CA-2919-00057>.



16. Gölbaşı O., Demirel N. A cost-effective simulation algorithm for inspection interval optimization: an application to mining equipment // *Computers & Industrial Engineering*. 2017. Vol. 113. P. 525–540. <https://doi.org/10.1016/j.cie.2017.09.002>.

17. Liu Z., Zuo M.J., Jin Y., Pan D., Qin Y. Improved local mean decomposition for modulation information mining and its application to machinery fault diagnosis // *Journal of Sound and Vibration*. 2017. Vol. 397. P. 266–281. <https://doi.org/10.1016/j.jsv.2017.02.055>.

18. Lazakis I., Raptodimos Y., Varelas T. Predicting ship machinery system condition through analytical reliability tools and artificial neural networks // *Ocean Engineering*. 2018. Vol. 152. P. 404–415. <https://doi.org/10.1016/j.oceaneng.2017.11.017>.

19. Равин А.А., Хруцкий О.В. Инженерные методы прогнозирования остаточного ресурса оборудования // *Вестник Астраханского государственного технического университета. Серия: Морская техника и технология*. 2018. № 1. С. 33–47. <https://elibrary.ru/yoqfau>, <https://doi.org/10.24143/2073-1574-2018-1-33-47>.

20. Черепанов А.П. Анализ преимуществ и недостатков современных методов прогнозирования ресурса технических устройств // *Вестник Ангарского государственного технического университета*. 2019. № 13. С. 90–101. <https://elibrary.ru/amcxvn>, <https://doi.org/10.36629/2686-777x-2019-1-13-90-101>.

21. Черепанов А.П. Методы прогнозирования ресурса единичных и уникальных машин // *Вестник Ангарского государственного технического университета*. 2022. № 16. С. 153–164. <https://elibrary.ru/eyvjgm>.

22. Полуянович Н.К., Дубяго М.Н., Огреничев А.В.,

Азаров Н.В. Оценка прогнозирования ресурса кабельных линий с использованием метода искусственных нейронных сетей // *Фундаментальные основы физики, химии и динамики наукоемких технологических систем формообразования и сборки изделий: сб. тр. науч. симпозиума технологов-машиностроителей. (с. Дивноморское, 2–5 октября 2019 г.)*. Дивноморское: Изд-во ДГТУ, 2019. С. 164–170. <https://elibrary.ru/IFGEUQ>.

23. Дзуганов В.Б., Анхудов Т.М., Болотоков А.Л., Губжиков Х.Л. Совершенствование методики прогнозирования распределения ресурса машин и их элементов // *Научная жизнь*. 2022. Т. 17. № 5. С. 793–804. <https://elibrary.ru/vzioft>, <https://doi.org/10.35679/1991-9476-2022-17-5-793-804>.

24. Гусев А.С., Стародубцева С.А., Щербаков В.И. Вероятностное прогнозирование долговечности и остаточного ресурса элементов конструкций // *Вестник машиностроения*. 2020. № 3. С. 39–40. <https://elibrary.ru/djwqnu>, <https://doi.org/10.36652/0042-4633-2020-3-39-40>.

25. Сай В.К., Щербаков М.В. Метод прогнозирования остаточного ресурса на основе обработки данных многообъектных сложных систем // *Прикаспийский журнал: управление и высокие технологии*. 2019. № 1. С. 33–44. <https://elibrary.ru/pzxhsl>.

26. Криков А.М., Федоров А.Г., Сидоренко М.Н. Совершенствование прогнозирования остаточного ресурса параметров узлов и агрегатов грузовых автомобилей // *Наземные транспортно-технологические средства: проектирование, производство, эксплуатация: материалы II Всеросс. науч.-практ. конф. (г. Чита, 30–31 октября 2018 г.)*. Чита: Изд-во ЗабГУ, 2018. С. 191–195. <https://elibrary.ru/zjgggv>.

References

1. Odeyar P., Apel D.B., Hall R., Zon B., Skrzypkowski K. A review of reliability and fault analysis methods for heavy equipment and their components used in mining. *Energies*. 2022;15(17):6263. <https://doi.org/10.3390/en15176263>.

2. Makhno D.E., Shadrin A.I. Resource management of mining equipment technical operation. *Vestnik Irkutskogo gosudarstvennogo tekhnicheskogo universiteta = Proceedings of Irkutsk State Technical University*. 2005;2:68-71. (In Russ.). <https://elibrary.ru/jxoeop>.

3. Khramovskikh V.A. Estimating operation life of basic units of opencast excavator metal structures based on statistical information processing. *Vestnik Irkutskogo gosudarstvennogo tekhnicheskogo universiteta = Proceedings of Irkutsk State Technical University*. 2005;1:167. (In Russ.). <https://elibrary.ru/jxklbf>.

4. Zheng S., Cheng K., Wang J., Liao Q., Liu X., Liu W. Failure analysis of frame crack on a wide-body mining dump truck. *Engineering Failure Analysis*. 2015;48:153-165. <https://doi.org/10.1016/j.engfailanal.2014.11.013>.

5. Benjumea D.C., Laniado H., Combita O. Analytical model to monitor the oil conditions on the main components of mining dumpers. *Results in Engineering*. 2023;17:100934. <https://doi.org/10.1016/j.rineng.2023.100934>.

6. Petrović D.V., Tanasijević M., Stojadinović S., Ivaz J., Stojković P. Fuzzy expert analysis of the severity of mining machinery failure. *Applied Soft Computing*. 2020;94:

106459. <https://doi.org/10.1016/j.asoc.2020.106459>.

7. Nepomnyashchikh K.A. Assessment methodology of mining machine reliability at the operational stage of the life cycle. In: *Prioritety mirovoi nauki: novye podkhody i aktual'nye issledovaniya: sb. nauch. tr. po materialam XXIX Mezhdunar. nauch.-prakt. konf. = Priorities of world science: new approaches and current research: collected scientific articles based on the materials of the 29th International scientific and practical conference*. 30 May 2022, Anapa. Anapa: LLC "Research Center for Economic and Social Processes" in the Southern Federal District; 2022, p. 142–150. (In Russ.). <https://elibrary.ru/ngpmef>.

8. Awan M.B., Li K., Li Z., Ma Z. A data driven performance assessment strategy for centralized chiller systems using data mining techniques and domain knowledge. *Journal of Building Engineering*. 2021;41:102751. <https://doi.org/10.1016/j.jobbe.2021.102751>.

9. Arjun S., Murthy L.R.D., Biswas P. Interactive sensor dashboard for smart manufacturing. *Procedia Computer Science*. 2022;200:49-61. <https://doi.org/10.1016/j.procs.2022.01.204>.

10. Dogan A., Birant D., Machine learning and data mining in manufacturing. *Expert Systems with Applications*. 2021;166:114060. <https://doi.org/10.1016/j.eswa.2020.114060>.

11. Lu Y.-J., Lee W.-C., Wang C.-H. Using data mining technology to explore causes of inaccurate reliability data



and suggestions for maintenance management. *Journal of Loss Prevention in the Process Industries*. 2023;83:105063. <https://doi.org/10.1016/j.jlp.2023.105063>.

12. Alamdari S., Basiri M.H., Mousavi A., Soofastaei A. Application of machine learning techniques to predict haul truck fuel consumption in open-pit mines. *Journal of Mining and Environment*. 2022;13(1):69-85. <https://doi.org/10.22044/jme.2022.11577.2145>.

13. Singh K., Maiti J., A novel data mining approach for analysis of accident paths and performance assessment of risk control systems. *Reliability Engineering & System Safety*. 2020;202:107041. <https://doi.org/10.1016/j.ress.2020.107041>.

14. Wang Z., Xia H., Zhang J., Yang B., Yin W. Imbalanced sample fault diagnosis method for rotating machinery in nuclear power plants based on deep convolutional conditional generative adversarial network. *Nuclear Engineering and Technology*. 2023;55(6):2096-2106. <https://doi.org/10.1016/j.net.2023.02.036>.

15. Szymahski Z., Paraszczak J. Application of artificial intelligence methods in diagnostics of mining machinery. *IFAC Proceedings Volumes*. 2007;40(11):403-408. <https://doi.org/10.3182/20070821-3-CA-2919.00057>.

16. Gölbaşı O., Demirel N. A cost-effective simulation algorithm for inspection interval optimization: an application to mining equipment. *Computers & Industrial Engineering*. 2017;113:525-540. <https://doi.org/10.1016/j.cie.2017.09.002>.

17. Liu Z., Zuo M.J., Jin Y., Pan D., Qin Y. Improved local mean decomposition for modulation information mining and its application to machinery fault diagnosis. *Journal of Sound and Vibration*. 2017;397:266-281. <https://doi.org/10.1016/j.jsv.2017.02.055>.

18. Lazakis I., Raptodimos Y., Varelas T. Predicting ship machinery system condition through analytical reliability tools and artificial neural networks. *Ocean Engineering*. 2018;152:404-415. <https://doi.org/10.1016/j.oceaneng.2017.11.017>.

19. Ravin A.A., Khrutsky O.V. Engineering methods for predicting the residual resource of the equipment. *Vestnik Astrakhanskogo gosudarstvennogo tekhnicheskogo universiteta. Seriya: Morskaya tekhnika i tekhnologiya = Vestnik of Astrakhan State Technical University. Series: Marine Engineering and Technologies*. 2018;1:33-47. (In Russ.). <https://elibrary.ru/yoqfau>, <https://doi.org/10.24143/2073-1574-2018-1-33-47>.

20. Cherepanov A.P. Analysis of advantages and disadvantages of modern methods forecasting the resource of technical devices. *Vestnik Angarskogo gosudarstvennogo*

tekhnicheskogo universiteta = Bulletin of the Angarsk State Technical University. 2019;13:90-101. (In Russ.). <https://elibrary.ru/amcxvn>, <https://doi.org/10.36629/2686-777x-2019-1-13-90-101>.

21. Cherepanov A.P. Of forecasting the resource of single and unique machines. *Vestnik Angarskogo gosudarstvennogo tekhnicheskogo universiteta = Bulletin of the Angarsk State Technical University*. 2022;16:153-164. (In Russ.). <https://elibrary.ru/eyvjgm>.

22. Poluyanovich N.K., Dubyago M.N., Ogrenichev A.V., Azarov N.V. Assessment of cable line resource forecasting using the method of artificial neural networks. In: *Fundamental'nye osnovy fiziki, khimii i dinamiki naukoemkikh tekhnologicheskikh sistem formobrazovaniya i sborki izdelii: sb. tr. nauch. simpoziuma tekhnologov-mashinostrotelei = Fundamental foundations of physics, chemistry and dynamics of science-intensive technological systems for product shaping and assembling: collection of papers of the scientific symposium of mechanical engineering technologists*. 2–5 October 2019, Divnomorskoe. Divnomorskoe: Don State Technical University; 2019, p. 164–170. (In Russ.). <https://elibrary.ru/IFGEUQ>.

23. Dzuganov V.B., Apkhudov T.M., Bolotkov A.L., Gubzhokov Kh.L. Improvement of the method for forecasting the resource distribution of machines and their elements. *Nauchnaya zhizn'*. 2022;17(5):793-804. (In Russ.). <https://elibrary.ru/vzioft>, <https://doi.org/10.35679/1991-9476-2022-17-5-793-804>.

24. Gusev A.S., Starodubtseva S.A., Shcherbakov V.I. Probabilistic forecasting of durability and residual life of structural elements. *Vestnik mashinostroyeniya*. 2020;3:39-40. (In Russ.). <https://elibrary.ru/djwqnu>, <https://doi.org/10.36652/0042-4633-2020-3-39-40>.

25. Sai V.K., Shcherbakov M.V. A data-driven method for remaining useful life prediction of multiple-component systems. *Prikladnyy zhurnal: upravlenie i vysokie tekhnologii = Caspian Journal: Management and High Technologies*. 2019;1:33-44. (In Russ.). <https://elibrary.ru/pzxhsl>.

26. Krikov A.M., Fedorov A.G., Sidorenko M.N. Improvement of residual life forecasting of truck unit and assembly parameters. In: *Nazemnye transportno-tekhnologicheskie sredstva: proektirovanie, proizvodstvo, ekspluatatsiya: materialy II Vseross. nauch.-prakt. konf. = Ground transport and technological means: design, manufacturing, operation: proceedings of the 2nd All-Russian scientific and practical conference*. 30–31 October 2018, Chita. Chita: Transbaikal State University; 2018, p. 191–195. (In Russ.). <https://elibrary.ru/zjgggv>.

Информация об авторах / Information about the authors



Храмовских Виталий Александрович,

кандидат технических наук, доцент,
доцент кафедры горных машин и электромеханических систем,
Институт недропользования,
Иркутский национальный исследовательский технический университет,
г. Иркутск, Россия,
✉ wax@istu.edu
<https://orcid.org/0000-0003-0590-0393>



Vitaliy A. Khramovskikh,
Cand. Sci. (Eng.), Associate Professor,
Associate Professor of the Department of Mining Machines
and Electromechanical Systems,
Institute of Subsoil Use,
Irkutsk National Research Technical University,
Irkutsk, Russia,
✉ wax@istu.edu
<https://orcid.org/0000-0003-0590-0393>



Шевченко Алексей Николаевич,
кандидат технических наук, доцент,
доцент кафедры горных машин и электромеханических систем,
директор Института недропользования,
Иркутский национальный исследовательский технический университет,
г. Иркутск, Россия,
shan@istu.edu
Aleksey N. Shevchenko,
Cand. Sci. (Eng.), Associate Professor,
Associate Professor of the Department of Mining Machines
and Electromechanical Systems,
Director of the Institute of Subsoil Use,
Irkutsk National Research Technical University,
Irkutsk, Russia,
shan@istu.edu



Непомнящих Кирилл Андреевич,
аспирант,
ассистент кафедры горных машин и электромеханических систем,
Институт недропользования,
Иркутский национальный исследовательский технический университет,
г. Иркутск, Россия,
nka@istu.edu
Kirill A. Nepomnyashchikh,
Postgraduate Student,
Assistant Professor of the Department of Mining Machines
and Electromechanical Systems,
Institute of Subsoil Use,
Irkutsk National Research Technical University,
Irkutsk, Russia,
nka@istu.edu

Вклад авторов / Contribution of the authors

Все авторы сделали эквивалентный вклад в подготовку публикации.
The authors contributed equally to this article.

Конфликт интересов / Conflict of interests

Авторы заявляют об отсутствии конфликта интересов.
The authors declare no conflicts of interests.
Все авторы прочитали и одобрили окончательный вариант рукописи.
The final manuscript has been read and approved by all the co-authors.

Информация о статье / Information about the article

Статья поступила в редакцию 19.05.2023; одобрена после рецензирования 31.05.2023; принята к публикации 15.06.2023.

The article was submitted 19.05.2023; approved after reviewing 31.05.2023; accepted for publication 15.06.2023.