

## Алгоритм контроля и диагностики технического состояния компрессорных установок с использованием нелинейных многопараметрических моделей

Я.В. МIRONENKO<sup>a</sup>, А.И. ХАЛЫСМАА<sup>b</sup>

Уральский федеральный университет имени первого Президента России Б.Н. Ельцина, ул. Мира, д. 19, Екатеринбург, Россия

<sup>a</sup> yaroslav.mironenko@inbox.ru, <sup>b</sup> a.i.khaliasmaa@urfu.ru

<sup>b</sup> <https://orcid.org/0000-0001-5327-6076>

Статья поступила 17.06.2025, принята 08.09.2025

*Надежная и эффективная эксплуатация компрессорных установок играет ключевую роль в стабильной работе предприятий нефтегазоперерабатывающей промышленности. В статье рассматривается разработка алгоритма контроля и диагностики технического состояния компрессорных установок на основе применения нелинейных многопараметрических моделей на основе методов машинного обучения. Цель исследования заключается в создании системы, способной автоматически контролировать и диагностировать техническое состояние компрессорных установок для обеспечения их функционирования в составе электротехнических комплексов предприятий нефтегазоперерабатывающей промышленности. Для достижения этой цели были поставлены задачи по формированию диагностической выборки, разработке и оптимизации моделей машинного обучения, а также определению влияния эксплуатационных факторов на точность классификации. Методы исследования включали построение моделей на базе алгоритмов стохастического разбиения данных и построения ансамблей деревьев решений. Диагностические данные получены из автоматизированных систем управления и эксплуатации оборудования. Полученные на наборе реальных производственных данных результаты показали, что включение эксплуатационных параметров позволяет значительно повысить точность диагностики. На тестовой выборке F1 мера точности классификации достигала 86 % при использовании предложенных многопараметрических моделей. Обоснована эффективность применения ансамблевых методов машинного обучения для решения рассмотренной задачи. Разработанный алгоритм обеспечивает высокую точность определения текущего состояния компрессорных установок (исправное, работоспособное, неисправное и предельное), что позволяет минимизировать риски отказов оборудования, повысить надежность технологических процессов и создать основу для дальнейшей автоматизации управления жизненным циклом компрессорных установок.*

**Ключевые слова:** компрессорная установка; нефтегазовая промышленность; машинное обучение; контроль; техническая диагностика; техническое состояние.

## Algorithm for monitoring and diagnostics of the technical condition of compressor units using nonlinear multiparameter models

Ya.V. MIRONENKO<sup>a</sup>, A.I. KHALYSMAA<sup>b</sup>

Ural Federal University named after the first President of Russia Boris Yeltsin; 19, Mira St., Ekaterinburg, Russia

<sup>a</sup> yaroslav.mironenko@inbox.ru, <sup>b</sup> a.i.khaliasmaa@urfu.ru

<sup>b</sup> <https://orcid.org/0000-0001-5327-6076>

Received 17.06.2025, accepted 08.09.2025

*Reliable and efficient operation of compressor units plays a key role in the stable operation of enterprises in the oil and gas refining industry. The article considers the development of an algorithm for monitoring and diagnosing the technical state of compressor units based on the use of nonlinear multiparameter models using machine learning methods. The purpose of the study is to create a system capable of automatically monitoring and diagnosing the technical state of compressor units to ensure their functioning as part of electrical complexes of enterprises in the oil and gas refining industry. To achieve this goal, the tasks are set to form a diagnostic sample, develop and optimize machine learning models, and determine the influence of operational factors on the accuracy of classification. The research methods include building models based on stochastic data partitioning algorithms and building ensembles of decision trees. Diagnostic data are obtained from automated control and equipment operation systems. The results obtained on a set of real production data show that the inclusion of operational parameters can significantly improve the accuracy of diagnostics. On the test sample, the F1 measure of classification accuracy reaches 86 % when using the proposed multiparameter models. The efficiency of using ensemble methods of machine learning to solve the considered problem is substantiated. The developed algorithm ensures high accuracy of determining the current state of compressor units (serviceable, operational, faulty and limiting), which allows one to minimize the risks of equipment failures, increase the reliability of technological processes and create a basis for further automation of compressor unit life cycle management.*

**Keywords:** compressor unit; oil and gas industry; machine learning; control; technical diagnostics; technical stat.

**Введение.** Эффективное и надёжное функционирование предприятий нефтегазоперерабатывающей промышленности в значительной степени обеспечивается безаварийной работой компрессорных установок. Компрессорная установка представляет собой агрегат в максимальной заводской готовности, объединяющий газовый компрессор и привод с целью минимизации капитальных затрат на строительство, сроков монтажа и отладки, удобства транспортировки, исключения выявления на месте установок нестыковок между отдельными её составляющими.

Компрессорные установки в нефтегазоперерабатывающей промышленности применяются в процессах сжатия: углеводородных газов в установках первичной переработки и подготовки газа; водородосодержащего газа для процессов гидроочистки, гидрокрекинга, изомеризации в комплексах глубокой переработки; азота и воздуха в блоках крекинга, получения серы и прочих.

В качестве привода в компрессорных установках могут использоваться электродвигатели, двигатели внутреннего сгорания, газовые и паровые турбины. В отличие от газотранспортных предприятий, где доля электроприводных компрессорных установок невелика и составляет менее 15 %, на предприятиях нефтегазоперерабатывающей промышленности общее количество электроприводных компрессорных установок превышает 80 % от общего числа используемых. Электроприводные компрессорные установки отличаются большей эффективностью и экологичностью. В качестве привода таких компрессорных установок, как правило, выступают синхронные и асинхронные двигатели (напряжением 6–10 кВ) мощностью от 4000 и до 4500 кВт соответственно.

Оборудование компрессорных установок функционирует в условиях непрерывного потока воздействий разнообразных факторов, как внешних, так и внутренних, под действием которых в соответствии с базовыми физическими законами изменяются его характеристики и свойства [1]. Изменение этих свойств и, как следствие, работоспособности всего комплекса при его создании, эксплуатации и ликвидации в условиях названных процессов составляют конечное множество состояний и режимов, которое представляет собой жизненный цикл. Использование выработавшего ресурс оборудования с ухудшенными эксплуатационными характеристиками многократно увеличивает риски отказов, которые могут быть весьма значительны и существенно превышать стоимость замены электрооборудования (ЭО), поскольку обусловлены не только затратами на его восстановление, но и длительными простоями, внеплановой остановкой производства, а также ущербом от перебоев в поставках энергоносителя и ликвидации последствий экологического загрязнения [2].

Создание системы контроля, диагностики и прогнозирования технического состояния компрессорных установок требует нового подхода к сбору и обработке данных, позволяющего анализировать поступающую информацию, исследовать работоспособность и качество функционирования комплекса, изучать и устанавливать признаки неисправностей отдельных элементов, прогнозировать развитие аварийных ситуаций и давать рекомендации по применению управляющих воздей-

ствий. Для обработки большого объёма данных онлайн-мониторинга перспективным является использование информационно-аналитических систем (ИАС) [3–5].

Описанию систем контроля компрессорных станций посвящена работа [6], в которой предлагается использование дополнительных датчиков для более полной оценки их энергоэффективности. В статье [7] описан подход к диагностике поршневого компрессора.

Вопросы контроля и диагностики компрессорных установок с использованием многопараметрических моделей в настоящее время слабо охвачены в научных исследованиях, несмотря на высокую актуальность обеспечения их надёжной работы [8, 9].

Анализ множества разнородных параметров в задачах технической диагностики ЭО может быть выполнен на основе моделей машинного обучения [10–14], как показано, например, для трансформаторного оборудования в работах [15–17].

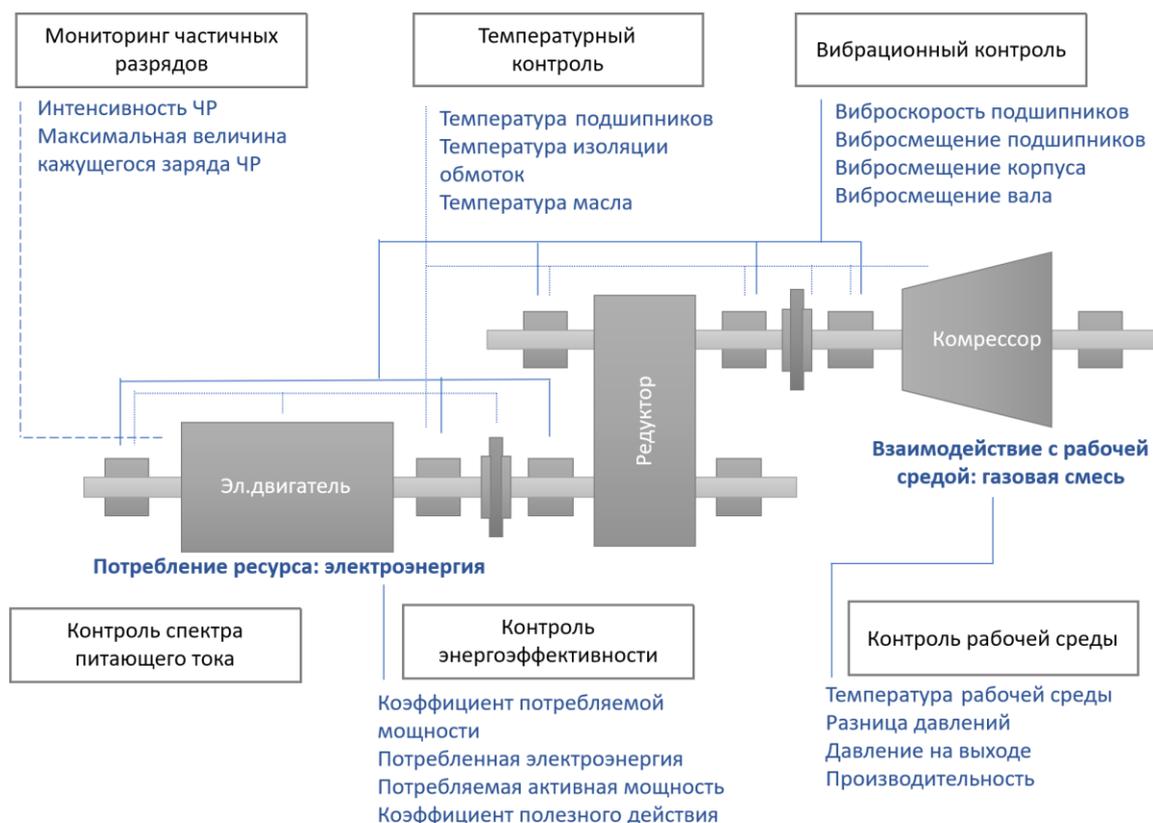
В конечном счёте контроль и диагностика ЭО, в том числе компрессорных установок с применением многопараметрических моделей направлена на автоматизацию и повышение эффективности процессов принятия решений при эксплуатации ЭО [18, 19].

**Анализ параметров для контроля работоспособности электроприводных компрессорных установок.** В первую очередь контроль работоспособности компрессорной установки характеризуется параметрами рабочей среды, представляющей собой различные газовые смеси. Состояние таких рабочих сред характеризуется температурой, давлением и объёмом. Следующие технологические параметры используются наиболее часто:

- разность давлений;
- выходное давление;
- температура рабочей среды;
- производительность.

Для контроля работоспособности и качества функционирования электроприводных компрессорных установок используются различные методы диагностики и мониторинга рабочей среды, а также вспомогательных систем установки для обеспечения её энергоэффективности. На рис. 1 представлена схема контроля и диагностики с отнесением применяемых методов к основным узлам.

Существенным недостатком использования указанных параметров для контроля и диагностики состояния конкретной электроприводной компрессорной установки является их применимость для всего технологического процесса в целом и, соответственно, зависимость от других составляющих процесса. Так, температура может вырасти из-за нагрева трубопровода, производительность упасть из-за изменения состава смеси, а разница давлений вырасти из-за отказа процесса на вышестоящем в цепочке агрегате. Тем не менее, данные параметры продолжают использоваться, в том числе для контроля и диагностики состояния конкретной установки, в первую очередь из-за оперативности поступления данных и массовой оснащённости измерительным оборудованием установок.



**Рис. 1.** Схема использования различных методов контроля работоспособности и качества функционирования электроприводных компрессорных установок

Контроль и диагностика технического состояния компрессорных установок осуществляется в первую очередь за счёт контроля диагностических параметров. Конкретный набор таких параметров определяется используемым методом диагностики в отношении компрессорной установки. Следующие методы диагностики получили наибольшее распространение:

- контроль вибрации;
- температурный контроль;
- мониторинг частичных разрядов;
- анализ потребляемого тока.

Контроль вибрации представляет собой эффективный метод контроля работоспособности компрессорной установки. Этот метод используется для мониторинга динамических характеристик оборудования и выявления потенциальных дефектов [20].

Температурный контроль производится для контроля работоспособности компрессорной установки в соответствии с IEC 60034-1 (стандарт определяет требования к измерению температуры и методам контроля температуры электродвигателей) и ISO 3966 (устанавливает методы контроля температуры для различных компонентов компрессорных установок).

В данной работе предложено также использовать следующие контролируемые параметры:

- потребляемую активную мощность;
- потребляемую реактивную мощность;
- напряжение;
- потребляемую электроэнергию;
- наработку;
- химический состав смазочного масла;

- давление смазочного масла;
- интенсивность частичных разрядов.

В то же время далеко не все параметры возможно использовать с учётом существующих систем мониторинга компрессорных установок, что также необходимо учитывать при разработке моделей контроля и диагностики их технического состояния.

**Классификация состояния компрессорных установок.** Диагностика состояния компрессорных установок производится разработанной моделью машинного обучения, решающей задачу классификации. В данном случае в качестве возможных рассматриваются три варианта состояния в соответствии с [22], и один вариант, характеризующий развивающиеся дефекты:

- «исправное», в котором все параметры объекта соответствуют всем установленным требованиям;
- не установленное нормативными документами «работоспособное», требующее внимания к возможным дефектам, в котором значения параметров объекта не превышают установленных показателей, но наблюдается высокий риск отказа;
- «неисправное» состояние отличается от «работоспособного» тем, что хотя бы один параметр объекта не соответствует как минимум одному из требований, но объект сохраняет способность выполнять заданные функции;
- «предельное», в котором дальнейшая эксплуатация объекта недопустима или нецелесообразна.

Определение состояния представляет собой задачу классификации, то есть создания алгоритма, способного определить принадлежность объекта к заданным

классам (состояниям). Решение задачи может быть проведено с помощью различных математических алгоритмов, в том числе на основе машинного обучения.

Ансамблевые методы представляют собой класс алгоритмов, который может быть эффективно применён в задачах классификации в технической диагностике [17]. Эти методы основаны на принципе объединения нескольких моделей в ансамбль с целью повышения точности и/или устойчивости к переобучению. В контексте технической диагностики, ансамблевые методы предоставляют следующие преимущества:

- увеличение стабильности, поскольку ансамбли объединяют прогнозы нескольких моделей, что делает выходные результаты более устойчивыми к шуму в данных и изменчивости в состояниях оборудования;

- улучшение обобщения, так как ансамбли способствуют снижению переобучения, что важно, особенно в случаях, когда данных о состоянии оборудования ограничено;

- увеличение точности – ансамбли могут значительно повысить точность классификации, так как объединение множества моделей позволяет учесть различные аспекты данных.

Решение задачи классификации состояния компрессорных установок требует комбинированного подхода, включая как технические методы, так и экспертное мнение, чтобы обеспечить надёжность и безопасность работы этого энергетического оборудования.

Выборка представляет собой набор данных, который используется для оптимизации и проверки моделей.

В технической диагностике выборка играет ключевую роль, поскольку качество и представительность данных напрямую влияют на эффективность моделей. Выборки бывают разных типов.

Обучающая выборка (*Training Data*) – это набор данных, который используется для обучения модели. Обычно он содержит множество примеров, где каждый пример представляет собой набор признаков и соответствующую метку класса или значение целевой переменной. Обучающая выборка позволяет модели учиться на исторических данных.

Валидационная выборка (*Validation Data*) – набор данных, который используется для настройки гиперпараметров модели и выбора лучших гиперпараметров. Он помогает оценить качество модели в процессе обучения и предотвратить переобучение.

Тестовая выборка (*Test Data*) – набор данных для итоговой оценки точности модели. Этот набор данных модель «видит» впервые после обучения, и оценка её работы на тестовой выборке помогает понять, насколько хорошо она обобщает данные обучающей выборки.

Несбалансированные выборки (*Imbalanced Data*). В реальных задачах диагностики данные о разных состояниях оборудования могут быть несбалансированными, то есть один класс может быть сильно представлен, а другой – мало. Это может потребовать специальных методов балансировки выборок, чтобы используемые модели были объективными.

Многоклассовые выборки (*Multiclass Data*). В случаях, когда состояния оборудования могут быть классифицированы на несколько категорий, задача классификации становится многоклассовой.

В технической диагностике правильный выбор и подготовка выборок играют решающую роль в эффективности систем диагностики [13]. Уделяя внимание выборкам, исследователи и инженеры обеспечивают надежное и точное функционирование систем мониторинга и диагностики технических систем [11, 12, 17].

**Описание набора данных и результатов вычислительных экспериментов.** Используемая выборка представляет собой объём данных из диагностических (АСДУЭ и АСУД) и эксплуатационных (АСУ ТП и АСКУ) систем, сформированных предшествующими измерениями и импортированными в виде неразмеченной информации в отношении выбранной компрессорной установки из распределённой базы данных. Для включения в выборку целевых показателей о состоянии компрессорных установок использовалась верифицированная информация из электронного журнала ремонтов (записи о дефектах и общем состоянии). Выборка не сбалансирована (для более чем 70 % компрессорных установок состояние определено как исправное), характеризуется сравнительно небольшим разбросом и достаточно высоким уровнем смещений. Данная характеристика является типичной для технической диагностики электрооборудования. Исходная выборка случайным образом разбита на две части – обучающую (75 % от общей) и тестовую (25 % от общей). Характеристики выборки представлены в табл. 1.

Диагностическая модель на основании метода стохастического разбиения данных была подготовлена на языке программирования *Python* с использованием библиотеки с открытым исходным кодом *Scikit-Learn* и алгоритма *BaggingClassifier*. В качестве оптимизационных параметров в данном алгоритме используются число классификаторов (*bootstrap*) и размер подмножества каждой выборки.

Используемый алгоритм "Bootstrap Aggregating" – это ансамблевый метод, который создает несколько базовых моделей и комбинирует их для получения более надёжной и устойчивой модели.

Модель итерационной оптимизации была также подготовлена на языке *Python*, но вместо классического алгоритма градиентного бустинга был использован алгоритм категориального бустинга и библиотека *CatBoost*.

Метрики качества в технической диагностике помогают оценить производительность модели. Два типа ошибок, которые учитываются в метриках – это ошибки первого и второго рода.

Ошибка первого рода (*False Positive, FP*) – ситуация, когда модель неверно классифицирует исправное состояние объекта как аномалию. Ошибка первого рода может привести к ложным тревожным сигналам в технической диагностике, что может потребовать дополнительных проверок и ресурсов.

Ошибка второго рода (*False Negative, FN*) – ситуация, когда модель неверно классифицирует аномалию как нормальное состояние объекта. Ошибка второго рода может быть критической, так как она может привести к упущению реальных аномалий и повысить риск необнаружения сбоев в оборудовании.

Выбор подходящих метрик зависит от конкретной задачи диагностики и баланса между ошибками перво-

го и второго рода. Например, в случаях, когда ложные тревожные сигналы дороги или критичны, специфичность может быть более важной метрикой. В других ситуациях, когда важно обнаружить как можно больше аномалий, полнота может иметь большее значение.

В рамках построения модели был проведён анализ влияния параметров алгоритма категориального бустинга. На первом этапе подбора наибольшее влияние на точность было оказано глубиной дерева. Зафиксировав значение глубины с наибольшей точностью, на втором этапе было выявлено наилучшее число базовых моделей. При этом число используемых данных перестало оказывать влияние на точность моделей. На третьем этапе было выбрано значение скорости оптимизации. С полученными значениями на четвёртом этапе представлена итоговая точность модели, которая никак не изменялась от количества данных.

В качестве оптимизационных параметров в алгоритме стохастического разбиения данных используются число классификаторов (*bootstrap*) и размер под-

множества каждой выборки. Относительно небольшой объём исходной выборки (количество рассматриваемых компрессорных установок в выбранных временных периодах) не позволяет оперировать вторым параметром оптимизации (по умолчанию равен 1). Оптимальное значение числа классификаторов было найдено для каждой выборки эмпирическим путем и составило 600–800 (по умолчанию 10).

Кроме указанной выше ансамблевой модели были также применены алгоритм *k*-ближайших соседей, метод опорных векторов, логистическая регрессия, однако их результаты оказались существенно слабее.

После оптимизации моделей была проведена тестовая проверка результатов контроля и диагностики текущего состояния компрессорных установок для разработанных моделей по размеченным данным из диагностических и эксплуатационных систем. Данные о точности работы моделей на тестовой выборке до и после оптимизации представлены в табл. 2.

Таблица 1. Характеристики набора данных

Характеристика	Исходная выборка с учетом эксплуатационных параметров	Исходная выборка без учёта эксплуатационных параметров
Количество объектов в выборке	29	29
Количество тегов для каждого объекта	до 126	до 95
Количество рассматриваемых периодов	8	8
Длина рассматриваемого периода, мин	131 400	131 400
Интеграционный параметр для тега, мин	от 1 до 30	от 2 до 30
Количество сценариев в выборке	232	232
Общий объём выборки для каждого сценария	до 7,5 млн	до 3 млн
Процент объектов, имеющих нулевые значения признаков	9 %	0 %
Распределение объектов по классам	71 / 19 / 9 / 1 %	71 / 19 / 9 / 1 %

Таблица 2. Результаты работы моделей классификации на тестовой выборке

Используемый алгоритм	Учёт эксплуатационных параметров	$F_1$ -мера до оптимизации модели	$F_1$ -мера после оптимизации модели
Стохастического разбиения данных	Нет	0,856	0,859
Стохастического разбиения данных	Есть	0,866	0,869
Итерационной оптимизации моделей ансамбля	Нет	0,810	0,827
Итерационной оптимизации моделей ансамбля	Есть	0,833	0,860

Для оценки работы модели используются следующие метрики качества: точность классификации ( $PPV$ ), полнота ( $TPR$ ) и гармоническое среднее между точностью и полнотой ( $F_1$ -мера):

$$PPV = \frac{TP}{TP + FP},$$

$$TPR = \frac{TP}{TP + FN},$$

$$F_1 = 2 \frac{PPV \cdot TPR}{PPV + TPR},$$

где  $TP$  – количество истинно положительных исходов;  $FP$  – количество ложноположительных исходов;  $FN$  – количество ложноотрицательных исходов.

В случае многоклассовой классификации в качестве метрики качества используется усреднение каждого элемента матриц ошибок при рассмотрении каждого класса, как бинарного (микроусреднение).

**Заключение.** В рамках исследования для решения задачи мультиклассовой классификации были выбраны методы, позволяющие достичь наибольшей точности в условиях несбалансированности выборки, присущей технической диагностике: алгоритм стохастического разбиения данных и итерационной оптимизации моделей ансамбля.

Использование указанных моделей для решения задачи классификации позволяет диагностировать состояние электротехнического комплекса с учётом множества эксплуатационных факторов: загрузки, условий внешней и внутренней среды. Для формирования мо-

делей была сформирована выборка, отличающаяся несбалансированностью (более 70 % компрессорных установок в исправном состоянии). По результатам оптимизации числа классификаторов и размера подмножества каждой выборки была достигнута точность классификации 86 %.

#### Литература

1. Косорлуков И.А. Прогнозирование жизненных циклов электроустановок 6–35 кВ на основе математического моделирования и оценки рисков отказов : дисс. ... канд. техн. наук / Косорлуков Игорь Андреевич ; Самарский гос. технический университет. – Самара, 2013. – 127 с.
2. Андреев Д.А., Назарычев А.Н. Управление жизненным циклом электроустановок при эксплуатации по техническому состоянию // Надежность и безопасность энергетики. – 2013. – № 3(22) – С. 32–36.
3. Mironenko Y.V., Khalyasmaa A.I. Maintenance Optimization Within the Lifecycle Management of the Gas Compressor's Electric Motors // International Conference of Young Specialists on Micro/Nanotechnologies and Electron Devices (EDM). Novosibirsk, 2023. – С. 1180–1185.
4. Mironenko Y.V., Khalyasmaa A.I. Development of Automated Life Cycle Management System for Electrically Driven Compressor Units in the Oil and Gas Industry // Belarusian-Ural-Siberian Smart Energy Conference (BUSSEC). – Ekaterinburg, 2023.
5. Казаков М.С., Давиденко И.В. Обзор интеллектуальных систем диагностики электрооборудования // Труды первой научно-технической конференции молодых ученых Уральского энергетического института, Екатеринбург, Россия, 16–20 мая 2016 г. – Екатеринбург, 2016. – С. 240–243.
6. Угольников А.В., Макаров Н.В. Применение систем автоматизации для контроля и учета показателей энергоэффективности эксплуатации компрессорного хозяйства горных предприятий // Записки Горного института. – 2019. – Т. 236. – С. 245–248.
7. Байков И.Р., Китаев С.В., Файрушин Ш.З. Диагностирование технического состояния поршневых компрессоров // Энергобезопасность и энергосбережение. – 2015. – № 3. – С. 28–30.
8. Захаров П.А., Захаров М.А. К вопросу о надежности электроприводного газоперекачивающего агрегата // Вестник ИГЭУ. – 2007. – № 3. – С. 1–3.
9. Гаврилюк Е.А., Манцеров С.А. Разработка стратегии обслуживания и ремонта оборудования газотранспортного предприятия на основе индекса технического состояния // Машиностроение и транспорт: теория, технология, производство. Труды НГТУ им. Р.Е. Алексеева. – 2017. – № 3 (118) – С. 121–126.
10. Клячкин В.Н., Кувайскова Ю.Е., Жуков Д.А. Выбор метода бинарной классификации при технической диагностике с применением машинного обучения // Известия Самарского научного центра Российской академии наук. – 2018. – Т. 20. № 4(3). – С. 494–497.
11. Gertler J., Costin M., Fang X., et al. Model based diagnosis for automotive engines-algorithm development and testing on a production vehicle // IEEE Transactions on Control Systems Technology. – 1995. – Vol. 3(1). – P. 61–69.
12. Masrur M.A., Chen Z., Zhang B., Murphey Y.Lu. Model-Based fault diagnosis in electric drives using artificial neural networks // IEEE Power Engineering Society General Meeting. Tampa, FL, USA, 2007.
13. Fenton W., McGinnity L., Maguire T. Fault diagnosis of electronic systems using intelligent techniques: a review // IEEE Transactions on Systems, Man, and Cybernetics, Part C. – 2000. – Vol. 31(3). – P. 269–281.
14. Мироненко Я.В., Курзанов А.Д. Оценка состояния изоляции электрооборудования с использованием алгоритма градиентного бустинга // Вестник Чувашского университета. – 2021. – № 3. – С. 94–102.
15. Ячиков И.М., Ларина Т.П., Храмина Е.А. Принятие решений о состоянии изоляции печного трансформатора с использованием обобщенного показателя на основе логики с нечеткими множествами // Вестник ЮУрГУ. Серия «Компьютерные технологии, управление, радиоэлектроника». – 2018. – Т. 18, № 2. С. 81–92.
16. Давиденко И.В. Разработка системы многоаспектной оценки технического состояния и обслуживания высоковольтного маслонаполненного электрооборудования дисс. ... докт. техн. наук / Давиденко Ирина Васильевна. – Екатеринбург, 2009. – 452 с.
17. Хальясмаа А.И. Машинное обучение как инструмент повышения эффективности управления жизненным циклом высоковольтного электрооборудования // Вестник Иркутского государственного технического университета. – 2020. – Т. 24. – № 5. – С. 1093–1104.
18. Крюков О.В., Гуляев И.В., Теплухов Д.Ю. Алгоритмы системы принятия решений при техническом обслуживании и прогнозировании автоматизированных электроприводов // Известия вузов. Электромеханика. – 2022. – Т. 65. – № 4. – С. 72–78.
19. Babichev S. A., Zakharov P. A., Kryukov O. V. Automated Monitoring System for Drive Motors of Gas-Compressor Units // Automation and Remote Control. – 2011. – Vol. 72(1). – P. 175–180.
20. Ковалёв В.К. Причины вибрации газоперекачивающих агрегатов // Транспорт и хранение нефтепродуктов и углеводородного сырья. 2014. – № 2. – С. 23–27.
21. ISO 14839-3:2006 Mechanical vibration. Vibration of rotating machinery equipped with active magnetic bearings. – Part 3. Evaluation of stability margin. – 2018. – 22 p.
22. ГОСТ Р 27.102-2021. Надежность в технике. Надежность объекта. Термины и определения. – М. : Российский институт стандартизации, 2021. – 35 с.

#### References

1. Kosorlukov I.A. Forecasting the life cycles of 6-35 kV electrical installations based on mathematical modeling and failure risk assessment: diss.... cand. of engineering sciences. Samara, 2013. – 20 p.
2. Andreev D.A., Nazarichev A.N. Life cycle management of electrical installations during operation according to their technical condition // Reliability and safety of energy. 2013. – № 3 (22) – P. 32–36.
3. Mironenko Y.V., Khalyasmaa A.I. Maintenance Optimization Within the Lifecycle Management of the Gas Compressor's Electric Motors // International Conference of Young Specialists on Micro/Nanotechnologies and Electron Devices (EDM). Novosibirsk, 2023. – С. 1180–1185.
4. Mironenko Y.V., Khalyasmaa A.I. Development of Automated Life Cycle Management System for Electrically Driven Com

- pressor Units in the Oil and Gas Industry // Belarusian-Ural-Siberian Smart Energy Conference (BUSSEC). Ekaterinburg, – 2023.
5. Kazakov M.S., Davidenko I.V. Review of intelligent diagnostic systems for electrical equipment // Proceedings of the first scientific and technical conference of young scientists of the Ural Power Engineering Institute, Ekaterinburg, Russia, May 16–20, 2016. – Ekaterinburg, 2016. – P. 240–243.
  6. Ugolnikov A.V., Makarov N.V. Application of automation systems for monitoring and recording energy efficiency indicators of compressor operations at mining enterprises // Notes of the Mining Institute. – 2019. – Vol. 236. – P. 245–248.
  7. Baikov I.R., Kitaev S.V., Fayrushin Sh.Z. Diagnostics of the technical condition of piston compressors // Energy safety and energy saving. – 2015. – № 3. – P. 28–30.
  8. Zakharov P.A., Zakharov M.A. On the reliability of an electric-driven gas-pumping unit // Bulletin of IGEU. – 2007. – № 3. – P. 1–3.
  9. Gavrilyuk E.A., Mancero S.A. Development of a strategy for servicing and repairing gas transmission company equipment based on the technical condition index // Mechanical engineering and transport: theory, technology, production. Proceedings of NSTU named after R. E. Alekseev. – 2017. – № 3 (118) – P. 121–126.
  10. Klyachkin V N., Kuvaiskova Yu.E., Zhukov D.A. Selection of a binary classification method for technical diagnostics using machine learning // Bulletin of the Samara Scientific Center of the Russian Academy of Sciences. – 2018. – Vol. 20. – № 4 (3). – P. 494–497.
  11. Gertler J., Costin M., Fang X., et al. Model based diagnosis for automotive engines-algorithm development and testing on a production vehicle // IEEE Transactions on Control Systems Technology. – 1995. – Vol. 3(1). – P. 61–69.
  12. Masrur M.A., Chen Z., Zhang B., Murphey Y.Lu. Model-Based fault diagnosis in electric drives using artificial neural networks // IEEE Power Engineering Society General Meeting. Tampa, FL, USA, 2007.
  13. Fenton W., McGinnity L., Maguire T. Fault diagnosis of electronic systems using intelligent techniques: a review // IEEE Transactions on Systems, Man, and Cybernetics, Part C. – 2000. vol. 31(3). – P. 269–281.
  14. Mironenko Ya.V., Kurzanov A.D. Assessment of the insulation condition of electrical equipment using the gradient boosting algorithm. Bulletin of the Chuvash University. – 2021. – №. 3. – P. 94–102.
  15. Yachikov I.M., Larina T.P., Khramshina E.A. Decision-making on the insulation condition of a furnace transformer using a generalized indicator based on fuzzy set logic // Bulletin of SUSU. Series «Computer technologies, control, radio electronics». – 2018. – Vol. 18(2). P. 81–92.
  16. Davidenko I.V. Development of a system for multi-aspect assessment of the technical condition and maintenance of high-voltage oil-filled electrical equipment dis. ... Doctor of Engineering Sciences. Ekaterinburg, 2009. – 452 p.
  17. Khalyasmaa A.I. Machine learning as a tool for improving the efficiency of life cycle management of high-voltage electrical equipment // Bulletin of the Irkutsk State Technical University. 2020. – Vol. 24. – № 5. – P. 1093–1104
  18. Kryukov O.V., Gulyaev I.V., Teplukhov D.Yu. Algorithms for the decision-making system for maintenance and forecasting of automated electric drives // Bulletin of universities. Electromechanics. – 2022. – V. 65. № 4. – P. 72–78.
  19. Babichev S.A., Zakharov P.A. Kryukov O.V. Automated Monitoring System for Drive Motors of Gas-Compressor Units // Automation and Remote Control. – 2011. – Vol. 72. (1). – P. 175–180.
  20. Kovalev V.K. Causes of vibration of gas pumping units // Transport and storage of oil products and hydrocarbon raw materials. – 2014. – № 2. – P. 23–27.
  21. ISO 14839-3:2006 Mechanical vibration. Vibration of rotating machinery equipped with active magnetic bearings. Part 3. Evaluation of stability margin. – 2018. – 22 p.
  22. GOST R 27.102-2021. Reliability in engineering. Reliability of an object. Terms and definitions. – M. : Russian Institute of Standardization, 2021. – 35 p.