

ОПТИМИЗАЦИЯ ЭКСПЛУАТАЦИИ МНОГОСЛОЙНЫХ КРИОГЕННЫХ СИСТЕМ С ПРИМЕНЕНИЕМ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ И СТАНДАРТИЗИРОВАННЫХ ПРОТОКОЛОВ ВНЕДРЕНИЯ

Астраханцева И.А., Котенев Т.Е., Горев С.В., Астраханцев Р.Г.

Астраханцева Ирина Александровна (ORCID 0000-0003-2841-8639), Котенев Тимофей Евгеньевич (ORCID 0009-0003-4963-2156), Горев Сергей Владимирович (ORCID 0000-0002-4370-9533), Астраханцев Роман Геннадьевич (ORCID 0000-0001-9880-2826)

Ивановский государственный химико-технологический университет,

г. Иваново, Россия. 153000, Ивановская область, г. Иваново, пр. Шереметевский, д. 7.

E-mail: i.astrakhantseva@mail.ru, kotenev@me.com, gorev@srosov.ru, rgastrakhantsev@gmail.com

В статье исследуются методы оптимизации управления многослойными криогенными системами с вакуумной изоляцией и азотным экраном с применением алгоритмов машинного обучения. Основное внимание уделяется минимизации потерь криогенных продуктов, повышению надежности хранения и транспортировки, а также интерпретируемости моделей для обоснованного принятия решений. Проведен анализ критически значимых технико-организационных параметров, влияющих на эксплуатацию криогенных систем, и рассмотрены подходы к адаптации алгоритмов машинного обучения с учетом специфики работы в экстремальных температурных условиях. Исследование включает разработку и валидацию алгоритмов прогнозирования параметров системы, таких как уровень и давление жидкого гелия, с использованием методов линейной регрессии, решающих деревьев и градиентного бустинга. Рассмотрены вопросы предобработки данных, включая устранение выбросов, заполнение пропусков и генерацию новых признаков, что позволяет повысить точность прогнозирования. Также сформулированы рекомендации по интеграции интеллектуальных алгоритмов в системы управления, обеспечивающие их промышленную применимость. Практическая значимость работы заключается в разработке стандартизированных протоколов внедрения алгоритмов машинного обучения, направленных на улучшение энергоэффективности и устойчивости работы криогенных систем. Результаты исследования могут быть использованы при проектировании новых криогенных систем и модернизации существующих инфраструктурных комплексов, что способствует повышению надежности и снижению эксплуатационных затрат.

Ключевые слова: многослойная криогенная система, вакуумная изоляция, жидкий гелий, машинное обучение, прогнозирование параметров, оптимизация управления, интерпретируемость моделей

OPTIMIZATION OF OPERATION OF MULTILAYER CRYOGENIC SYSTEMS USING MACHINE LEARNING METHODS AND STANDARDIZED IMPLEMENTATION PROTOCOLS

Astrakhantseva I.A., Kotenev T.E., Gorev S.V., Astrakhantsev R.G.

Astrakhantseva Irina Aleksandrovna (ORCID 0000-0003-2841-8639), Kotenev Timofey Evgenievich (ORCID 0009-0003-4963-2156), Gorev Sergey Vladimirovich (ORCID 0000-0002-4370-9533), Astrakhantsev Roman Gennadievich (ORCID 0000-0001-9880-2826)

Ivanovo State University of Chemical Technology,

Ivanovo, Russia. 153000, Ivanovo region, Ivanovo, Sheremetevsky Ave., 7.

E-mail: i.astrakhantseva@mail.ru, kotenev@me.com, gorev@srosov.ru, rgastrakhantsev@gmail.com

The paper investigates methods for optimizing the control of multilayer cryogenic systems with vacuum insulation and nitrogen shield using machine learning algorithms. The main focus is on minimizing the loss of cryogenic products, increasing the reliability of storage and transportation, and interpretability of models for informed decision making. An analysis of critical technical and organizational parameters affecting the operation of cryogenic systems was carried out, and approaches to

adapting machine learning algorithms taking into account the specifics of work in extreme temperature conditions were considered. The research involves the development and validation of algorithms for predicting system parameters such as liquid helium level and pressure using linear regression, decision trees and gradient boosting methods. The issues of data preprocessing are considered, including the elimination of outliers, filling gaps and generating new features, which allows for increasing the accuracy of forecasting. Recommendations are also formulated for integrating intelligent algorithms into control systems, ensuring their industrial applicability. The practical significance of the work lies in the development of standardized protocols for the implementation of machine learning algorithms aimed at improving the energy efficiency and sustainability of cryogenic systems. The results of the study can be used in the design of new cryogenic systems and the modernization of existing infrastructure complexes, which helps to increase reliability and reduce operating costs.

Keywords: multilayer cryogenic system, vacuum insulation, liquid helium, machine learning, parameter prediction, control optimization, model interpretability

ВВЕДЕНИЕ

Криогенные системы занимают особое место в технических системах. Это связано с тем, что их функционирование связано с экстремально низкими температурами. Этот фактор усложняет задачи управления такими системами. Достижение высокой точности, надежности и энергоэффективности в условиях экстремальных температур в управлении криогенными системами является актуальной научной и промышленной задачей [1].

Разработка прикладных методов и алгоритмов машинного обучения для минимизации потерь криогенных продуктов, повышения эффективности хранения и транспортировки, а также улучшения надёжности многослойной криогенной системы с вакуумной изоляцией и азотным экраном представляет собой сложный многоступенчатый процесс. Он включает в себя:

- анализ существующих методов управления многослойными криогенными системами и выявление их ограничений;
- разработку архитектуры системы поддержки принятия решений на основе алгоритмов машинного обучения для оптимизации управления многослойной криогенной системой;
- разработку алгоритмов прогнозирования изменения ключевых параметров системы, обеспечивающих точность и стабильность управления;
- исследование и внедрение методов преобразования данных, включая устранение выбросов, заполнение пропусков и генерацию новых признаков, с целью повышения качества анализа данных;
- проведение валидации разработанных алгоритмов на реальных данных из сенсорных систем криогенных контейнеров, оценить их точность и эффективность;
- разработка рекомендаций по интеграции методов в существующие системы управления для обеспечения их промышленной применимости.

Разработка рекомендаций по интеграции методов в системы управления является ключевым завершающим этапом изучения, разработки и внедрения алгоритмов машинного обучения в управление многослойной криогенной системой для обеспечения ее эффективной работы [2].

МЕТОДЫ И МАТЕРИАЛЫ

Основные исследования в области управления криогенными системами затрагивают вопросы минимизации теплопередачи, разработки материалов для вакуумной изоляции, интеллектуализация управления и мониторинга, а также прогнозирование отказов и обеспечение надежности конструкций [3].

Методологическая основа исследования базируется на комплексе общенаучных методов, включая анализ, синтез, системный и структурный подходы, а также сравнительный анализ и экспертные оценки. Применяются методы научной абстракции и обобщения, систематизация и группировка данных, а также их табличное и графическое представление для обеспечения объективности и всесторонности анализа в области управления многослойной криогенной системой [4].

Используются методы машинного обучения для управления многослойной криогенной системой, включая логистическую регрессию, случайный лес, градиентный бустинг. Исследование включает использование современных информационных технологий для обработки больших объемов данных и визуализации результатов, что обеспечивает поддержку в принятии управленческих решений.

Используются современные информационные технологии и программное обеспечение для обработки больших объемов данных, визуализации результатов и поддержки принятия решений на основе проведенного анализа.

АНАЛИЗ ПРЕДМЕТНОЙ ОБЛАСТИ

Применение методов машинного обучения в управлении криогенными системами основано на следующей методологии построения моделей [5]:

1. Анализ и предобработка данных.
2. Формирование признаков.
3. Формирование обучающей выборки:
4. Настройка моделей.
5. Оценка и валидация моделей.
6. Интеграция алгоритмов в систему

Анализ и предобработка данных представляет собой начальный этап разработки моделей, на котором изучаются источники данных и их структура. Источниками данных для криогенной системы являются сенсоры, регистрирующие параметры работы оборудования, такие как температура, давление, уровни азота и гелия, а также параметры окружающей среды. Основные шаги предобработки включают:

Удаление выбросов. Выбросы могут возникать из-за ошибок сенсоров или аномальных событий. Они устраняются с использованием методов анализа распределений данных, таких как Z-score или интерквартильный размах [6].

Заполнение пропущенных значений. Пропуски в данных могут быть вызваны неисправностями оборудования или неполным сбором данных. В случае отсутствующих данных применяются методы линейной интерполяции или моделирования пропусков с использованием алгоритмов машинного обучения (например, случайного леса), которые позволяют корректно восстановить пропущенные значения.

Масштабирование признаков. Алгоритмы машинного обучения, такие как градиентный бустинг или логистическая регрессия, требуют приведения данных к единому масштабу для повышения стабильности обучения.

Анализ корреляции. Для исключения избыточных данных используется анализ корреляций, PCA (анализ главных компонент), что позволяет упростить вычисления и улучшить интерпретируемость моделей.

Формирование признаков (“фичей”) является критически важным этапом, так как их качество определяет эффективность моделей машинного обучения. Признак (feature) представляет собой переменную, которая описывает отдельную характеристику объекта и является фундаментальной составляющей в задачах машинного обучения. Именно на основе признаков строятся предсказания в моделях [7]. Формирование обучающей выборки заключается в разделении данных на обучающую, тестовую и валидационную

выборки для обеспечения надежности оценки моделей. Первоначальная выборка данных может содержать пропуски, выбросы или шум. Предварительная обработка включает очистку данных, нормализацию, кодирование категориальных переменных и другие шаги, чтобы подготовить данные к обучению. Обучающая выборка (Training set) как правило составляет 60-80% от общего объема данных, она используется для обучения модели. Валидационная выборка (Validation set) составляет около 10-20% от общего объема данных и используется для настройки гиперпараметров модели и предотвращения переобучения. Валидационная выборка помогает оценить, как модель будет работать на новых данных. Тестовая выборка (Test set) составляет порядка 10-20% от общего объема данных и используется для окончательной оценки производительности модели после завершения обучения и настройки [8].

Разделение данных может осуществляться случайным образом. Это наиболее распространенный метод, однако в случае его использования важно следить за тем, чтобы распределение классов было сбалансированным. Стратифицированное разделение используется в случае, если в исходных данных несбалансированные классы. В этом случае данные делятся так, чтобы пропорции классов в обучающей, валидационной и тестовой выборках были аналогичны пропорциям в исходных данных. В некоторых случаях используется метод кросс-валидации, при котором данные многократно делятся на обучающую и тестовую выборки, и модель обучается и оценивается на разных подвыборках. После разделения данных и обучения модели важно оценить ее производительность на тестовой выборке [9].

На этапе выбора алгоритмов для решения задач прогнозирования и классификации в криогенных системах были отобраны логистическая регрессия, случайный лес, градиентный бустинг (XGBoost, LightGBM). Логистическая регрессия выбрана по причине простоты, скорости обучения и высокой интерпретируемости. Случайный лес, как отмечалось выше, хорошо справляется с анализом данных, содержащих шум, и позволяет оценивать значимость признаков. Метод используется как для задач классификации, так и регрессии. Градиентный бустинг подходит для построения сложных прогнозирующих моделей, обеспечивает высокую точность, но требует больших вычислительных ресурсов и тщательной настройки. На этапе настройки моделей проводится оптимизация гиперпараметров для достижения наилучшей производительности алгоритмов.

Для достижения цели могут быть использованы методы Grid search, Random search и байесовская оптимизация. Grid search представляет собой перебор всех возможных комбинаций параметров для поиска оптимальных настроек. Random search является более эффективным методом, позволяющим сэкономить время за счет случайного выбора комбинаций. Байесовская оптимизация применяется для сложных моделей, таких как градиентный бустинг, для поиска глобального оптимума гиперпараметров [10]. Для оценки эффективности разработанных моделей машинного обучения в рамках исследования использовались современные метрики, позволяющие всесторонне оценить качество их предсказаний и адаптировать модели к особенностям данных. Метрики для алгоритмов являются ключевым моментом для оценки и сравнения эффективности методов в машинном обучении, характеристик данных и влияния на интерпретацию результатов. После выбора и настройки модели она интегрируется в систему управления криогенной системой. Основные шаги интеграции включают разработку API для взаимодействия моделей с системой управления, постоянный мониторинг работы моделей и обновление их на основе новых данных и реализацию механизмов автоматического оповещения при выявлении отклонений в параметрах системы [11]. Выделенные признаки и выбранные алгоритмы формируют основу для создания интеллектуальных систем управления многослойными криогенными системами. Использование логистической регрессии, случайного леса и градиентного бустинга позволяет решать широкий спектр задач - от прогнозирования теплоток до предотвращения отказов оборудования. Эффективное применение методов машинного обучения для управления многослойными криогенными системами требует корректной предобработки данных. На данном этапе осуществляется приведение исходных данных к единому формату, устранение пропусков и выбросов, а также создание новых признаков для повышения эффективности моделей. Применение этих методов обеспечивает повышение качества данных, улучшает их интерпретируемость и оптимизирует последующее обучение моделей [12].

Методами обработки данных являются:

1. Чтение и очистка данных.
2. Преобразование числовых данных.
3. Кодирование категориальных признаков.
4. Генерация новых признаков.
5. Снижение размерности.
6. Разделение данных.

Чтение и очистка данных заключается в том, что данные, поступающие из сенсорных систем, представлены в виде таблиц, содержащих временные метки, параметры уровня и давления жидкого гелия и азота, а также метки статуса контейнера и управленческих решений [13].

Для обработки данных использовались следующие подходы:

1. Загрузка данных.
2. Обработка пропущенных данных.
3. Удаление выбросов.

Данные загружались из исходного CSV-файла с использованием библиотеки pandas. Непопулярные столбцы и данные, не относящиеся к целям исследования, были удалены с использованием метода Drop ().

Пропуски в числовых признаках, например, уровнях и давлениях гелия и азота, заполнялись с использованием методов линейной интерполяции. Для категориальных признаков, таких как "Статус контейнера", использовался метод ближайших соседей (KNN), который позволяет учитывать взаимосвязь между соседними записями.

Для удаления аномальных значений применялся метод межквартильного размаха (IQR). Данный метод основан на анализе квартилей, где:

Q1 (первый квартиль) – значение, ниже которого находится 25% данных;

Q3 (третий квартиль) – значение, ниже которого находится 75% данных.

IQR (межквартильный размах) рассчитывается как разница между Q3 и Q1 ($IQR = Q3 - Q1$).

Значения, выходящие за границы $[Q1 - 1.5 \times IQR]$ и $[Q3 + 1.5 \times IQR]$, считались выбросами и заменялись медианными значениями соответствующих столбцов.

Преобразование числовых данных осуществляется путем нормализации и масштабирования, а также обработки некорректных значений.

Нормализация и масштабирование заключалось в том, что все числовые признаки (например, давление He и N₂, уровни He и N₂) были приведены к диапазону [0, 1] методом Min-Max Scaling. Это позволило устранить дисбаланс в шкалах признаков и обеспечить стабильность алгоритмов машинного обучения.

Преобразование числовых данных включает в себя обработку некорректных значений. Для данных, содержащих дробные числа с разделителем в виде запятой, применялось преобразование в формат с точкой с помощью метода str.replace(). Числовые признаки приводились к типу float64 для унификации формата данных [14].

Для кодирования категориальных признаков такие признаки, как «Статус контейнера» и «Управленческое решение», были преобразованы в числовой формат для обеспечения совместимости с алгоритмами машинного обучения:

1. Бинарное кодирование.
2. One-Hot Encoding.

Бинарным кодированием признак «Статус контейнера» был закодирован: "В пути" → 0, "В покое" → 1. Аналогично, "Управленческое решение" кодировалось как 0 для "Оставить без действий" и 1 для "Требуется действие".

При необходимости для многозначных категорий использовалось одноразрядное кодирование, которое расширяет категориальный признак в несколько бинарных столбцов.

Для повышения эффективности моделей были созданы дополнительные признаки:

1. Взаимодействия между признаками.
2. Логарифмическое преобразование.
3. Создание бинарных индикаторов.

С использованием метода Polynomial Features были созданы взаимодействующие признаки, такие как произведение уровня и давления гелия [Уровень He × Давление He] и уровня и давления азота [Уровень N₂ × Давление N₂]. Это позволило учесть сложные взаимосвязи между физическими параметрами [15].

Для признаков давления использовалось логарифмическое преобразование (с добавлением 1) для уменьшения влияния высоких значений и улучшения распределения данных.

Путем создания бинарных индикаторов, был добавлен признак-индикатор "LI-02 уровень N₂ = 0", который указывал на случаи полного отсутствия азота в системе.

С целью снижения размерности, исключения избыточности данных и ускорения работы алгоритмов был выполнен анализ корреляции между признаками. Высококоррелированные признаки, такие как давление и уровень для одной среды, исключались или заменялись на интегральные показатели [16].

Для обеспечения качественного обучения моделей для датасет было осуществлено разделение данных на обучающую и тестовую выборки с использованием метода train_test_split. Разделение проводилось с учётом сохранения баланса классов и соотношения выборок. Для сохранения баланса классов использовалось стратифицированное разделение для равномерного распределения меток целевой переменной в выборках. Соотношение выборок было следующим: 80% данных выделялось для обучения, а 20% – для тестирования.

Этап предобработки данных включал очистку, нормализацию, генерацию новых признаков и снижение размерности, что обеспечило готовность данных для построения моделей машинного обучения. Используемые методы позволили улучшить качество данных, минимизировать шумы и выбросы, а также учесть ключевые зависимости между параметрами. Этот процесс является неотъемлемой частью разработки интеллектуальных алгоритмов для управления многослойными криогенными системами.

Реализация алгоритмов машинного обучения была осуществлена с использованием логистической регрессии, метода случайного леса и градиентного бустинга. По итогам реализации алгоритмов установлено, что для классификационных задач первичной диагностики состояния системы с точки зрения обнаружения аномальных режимов следует применять метод логистической регрессии. Метод случайного леса предлагается использовать для оценки взаимосвязей между параметрами и детальных прогнозных оценок характера термодинамических процессов. При высоконе линейных зависимостях для прогностического анализа между параметрами в многослойных криогенных контурах внедряются градиентные бустинговые алгоритмы [17].

Методы предобработки данных, включающие очистку, нормализацию, генерацию новых признаков и снижение размерности, способствуют улучшению качества данных, минимизации шумов и выбросов, учету значимых зависимостей между параметрами. Для улучшения информативности набора данных, повышения эффективности и точности прогнозных моделей проведена генерация новых признаков на основе взаимодействий между параметрами, существующими в наборе данных, с использованием метода полиномиальной регрессии. Новые признаки интегрированы в исходный набор данных путем конкатенации, выполнена операция очистки данных от пропущенных значений и сброса индексации для консистентности структуры данных.

РЕЗУЛЬТАТЫ И ДИСКУССИИ

Методы и алгоритмы интеллектуального управления многослойными криогенными системами с вакуумной изоляцией и охлаждением жидким азотом позволяют минимизировать потери криогенных продуктов, повысить эффективность процессов хранения и транспортировки, улучшить надежность функционирования системы. Алгоритмы прогнозирования учитывают сложные временные зависимости и взаимодействия между па-

параметрами системы. В свою очередь, разработка формализованных рекомендаций по интеграции сформированных интеллектуальных алгоритмов в функциональную архитектуру существующих систем оперативного контроля и регулирования многослойных криогенных инфраструктурных комплексов представляет собой ключевое звено данной исследовательской работы, посвященной разработке прикладных методов и алгоритмов машинного обучения для управления многослойными криогенными системами. Цель данной работы заключается в повышении индустриальной применимости и технологической готовности предложенных решений путем детальной адаптации вычислительных методов машинного обучения к специфике реальных условий эксплуатации, а также в формализации стандартов и протоколов внедрения [18].

Сбор данных осуществляется путем автоматического получения параметров системы через устройства с дальнейшим сохранением данных в базе для последующей обработки. Программное обеспечение для сбора данных, описывающее состояние многослойной криогенной системы, разработано на платформе ASP.NET Core, что позволяет достичь высокой гибкости и масштабируемости системы. Такая архитектура обеспечивает возможность эффективной интеграции с существующими системами управления и адаптации к новым задачам. Программное обеспечение имеет модульную структуру, благодаря которой обеспечивается распределение функционала между компонентами и повышение устойчивости системы к изменениям эксплуатационных условий [19].

Основой работы системы являются контроллеры, которые выполняют обработку запросов и взаимодействуют с внешними источниками данных. Ключевыми из них являются WayList Controller, UserController и RoleController. WayListController управляет маршрутными листами, осуществляет сбор параметров системы, таких как уровни и давления жидкого гелия и азота. Данный контроллер выполняет первичную обработку данных, что снижает нагрузку на пользовательские интерфейсы и повышает надежность работы системы. UserController занимается управлением учетными записями пользователей, их аутентификацией и предоставлением доступа к функционалу. RoleController регулирует распределение прав доступа пользователей, что способствует защите данных и разграничению полномочий в рамках системы [20]. Модели данных включают в себя структуры User и WayList, используемые для опи-

сания данных в системе. Модель пользователя (User) содержит информацию о роли, идентификаторах и доступах. Модель WayList описывает параметры системы, включая сенсорные данные, такие как уровни и давления азота и гелия.

База данных управляется через Application DbContext, что обеспечивает взаимодействие между моделями данных и реляционной базой данных. Entity Framework используется для автоматизации операций с базой данных, таких как создание, чтение, обновление и удаление (CRUD).

Аутентификация и авторизация реализована с помощью AuthOptions и TokenUtils, которые обеспечивают генерацию JWT-токенов и защиту данных.

Вспомогательными утилитами являются HelperMethods и YandexMapsApi. HelperMethods содержит функции для работы с токенами и паролями. YandexMapsApi предоставляет возможность интеграции с внешними API для получения геолокационных данных.

Программное обеспечение обладает функциональными возможностями сбора, хранения, обработки данных, интеграции с алгоритмами машинного обучения, управлением доступом и визуализации. Описание функциональных возможностей представлено в следующей таблице 1.

Программное обеспечение предназначено для сбора и обработки данных, которые используются для построения моделей прогнозирования и оптимизации управления многослойными криогенными системами. Основные этапы интеграции включают сбор и анализ данных, прогнозирование, принятие решений, мониторинг и улучшение.

Сбор данных осуществляется путем автоматического получения параметров системы через сенсорные устройства с дальнейшим сохранением данных в базе для последующей обработки. Анализ данных включает в себя предварительную обработку и генерацию новых признаков, таких как произведение уровней и давлений жидкого гелия и азота, а также выявление аномалий и подготовку данных для обучения моделей.

Использование алгоритмов машинного обучения для предсказания необходимости долива азота или других корректирующих действий. Интеграция с задачами исследования включает автоматизацию решений на основе прогнозов, генерируемых системой. Процесс мониторинга осуществляется через визуализацию состояния системы, анализ прогнозов для оценки их точности. Улучшение алгоритмов происходит на основе обратной связи с пользователем.

Функциональные возможности программного обеспечения

Table 1. Software functionality

Функциональные возможности	Описание
Сбор и хранение данных	Сенсорные данные, такие как уровень и давление жидкого гелия и азота, передаются через контроллер WayListController и сохраняются в базе данных с использованием модели WayList.
Обработка данных	Предусмотрены методы предобработки данных, включая фильтрацию выбросов и приведение данных к стандартизированным форматам. Данные обрабатываются для подготовки к прогнозированию, включая создание новых признаков на основе исходных параметров.
Интеграция с алгоритмами машинного обучения	Алгоритмы, такие как логистическая регрессия, случайный лес и градиентный бустинг, могут быть интегрированы для прогнозирования изменений параметров системы. Обработка данных и генерация прогнозов осуществляется через заранее подготовленные входные данные из базы.
Управление доступом	Система поддерживает управление ролями и правами доступа через RoleController и UserController. Это позволяет разграничить доступ к данным и функциям системы между различными категориями пользователей.
Визуализация	Использование ErrorViewModel позволяет отображать ошибки и состояния системы в пользовательском интерфейсе. В будущем возможно добавление графиков и диаграмм для мониторинга параметров системы в реальном времени.

Данные системы включают широкий спектр параметров, которые собираются для анализа и прогнозирования. К основным параметрам относятся:

- Температура внешней среды: позволяет учитывать влияние внешних факторов на теплопередачу и состояние криогенной системы.

- Мониторинг показателей уровня жидкого азота и гелия критически важен для обеспечения стабильности работы системы и предотвращения потерь криогенных продуктов.

- Данные о давлении в резервуарах для азота и гелия необходимы для контроля герметичности системы, предотвращения утечек и обеспечения оптимального состояния жидкостей.

- Фиксация времени для каждого набора данных позволяет отслеживать динамику изменений и выявлять временные закономерности.

- Информация о текущем состоянии контейнера (в пути, в покое) используется для адаптации прогнозных моделей и управления системой.

Собранные данные формируют датасет, который является основой для применения алгоритмов машинного обучения. Этот датасет представляет собой таблицу, где строки соответствуют наблюдениям, а столбцы - различным параметрам системы. Каждый набор данных включает временные метки, значения параметров (давления, уровни жидкостей, температура) и статус контейнера. Кроме того, датасет может содержать вычисленные признаки, такие как взаимодействие уровней и давлений, что позволяет улучшить точ-

ность моделей машинного обучения. Перед использованием в модели данные проходят этап предобработки, который включает в себя:

1. Очистку данных: устранение выбросов, пропущенных значений и аномалий, которые могут исказить результаты анализа.
2. Стандартизацию и нормализацию: приведение параметров к единой шкале, что особенно важно для алгоритмов, чувствительных к масштабу данных.
3. Формирование новых признаков: создание производных показателей, таких как взаимодействие уровня и давления жидкостей, что позволяет улучшить качество моделей.

После этапа предобработки данные передаются в программный модуль, который реализует алгоритмы машинного обучения. В рамках системы применяются алгоритмы логистической регрессии, случайного леса и градиентного бустинга.

Логистическая регрессия используется для анализа зависимостей между параметрами системы и вероятностью возникновения отклонений. Случайный лес применяется для учета сложных нелинейных взаимодействий между признаками, таких как давление и уровень жидкостей. Градиентный бустинг позволяет строить высокоточные модели, которые учитывают множественные факторы и обеспечивают прогнозирование аномалий в работе системы.

Модели обучаются на исторических данных, содержащих как нормальные, так и аномальные состояния системы.

В процессе обучения используется перекрестная проверка, чтобы оценить качество моделей и избежать переобучения. После обучения модели интегрируются в управляющую систему и используются для прогнозирования возможных отклонений и принятия решений. Например, при снижении уровня жидкого азота или увеличении давления система автоматически рекомендует корректирующие действия, такие как добавление азота. Интеграция датасета в программное обеспечение реализована через интерфейсы взаимодействия с базой данных. Система обеспечивает автоматическую загрузку новых данных, обновление существующих записей и предоставление данных для анализа в реальном времени.

Это позволяет обеспечить непрерывную работу системы и своевременное реагирование на изменения параметров.

Осуществление взаимодействия с данными обеспечено применением инструментов ORM Entity Framework Core, что упрощает взаимодействие с реляционной базой данных и позволяет быстро масштабировать решение. Визуализация данных в пользовательском интерфейсе реализована с использованием JavaScript-фреймворка, такого как React или Angular, что делает взаимодействие с системой удобным и интуитивным.

В работе программы также активно используются популярные библиотеки для обработки и анализа данных, такие как Pandas и NumPy, которые позволяют эффективно управлять массивами данных и выполнять предварительный анализ. Для реализации алгоритмов машинного обучения применяется библиотека Scikit-learn, которая предоставляет широкий набор инструментов для создания, обучения и валидации моделей. Интеграция сложных методов прогнозирования, таких как градиентный бустинг, выполнена с использованием библиотек XGBoost и LightGBM, что позволяет достичь высокой точности прогнозов. Дополнительно используется библиотека Matplotlib для визуализации результатов анализа, что позволяет получить наглядное представление о динамике параметров системы и результатах работы моделей. Для обеспечения безопасности и управления доступом применяются инструменты для работы с JWT-токенами и шифрования данных. Система также поддерживает интеграцию с внешними API, такими как Yandex Maps API, что позволяет учитывать географическую составляющую в процессе анализа.

Таким образом, разработанное программное обеспечение предоставляет полный цикл работы с данными - от их сбора и обработки до анализа и принятия решений. Интеграция алгоритмов ма-

шинного обучения в управляющую систему позволяет значительно повысить эффективность и надежность работы многослойных криогенных систем, минимизировать потери криогенных продуктов и сократить эксплуатационные риски.

Использование современного технологического стека и передовых библиотек обеспечивает высокую производительность и адаптивность системы, делая ее перспективным инструментом для дальнейших исследований и внедрения в промышленность. Реализация интеграционных мероприятий в условиях уже развернутых систем управления, предназначенных для многослойных криогенных сред, требует учета ряда критически значимых технико-организационных и эксплуатационных параметров:

1. Техническая совместимость и инфраструктурная прозрачность.
2. Модульная композиция и сегментация функционала.
3. Стандартизация и унификация входных данных.
4. Оптимизация вычислительных затрат и эффективное распределение ресурсов
5. Интерпретируемость и доверие к моделям.
6. Кибербезопасность и устойчивость к отказам.
7. Тестирование и пилотные испытания в реальных условиях.

Для успешной интеграции разработанных интеллектуальных алгоритмов в функциональную архитектуру существующих систем оперативного контроля и регулирования многослойных криогенных инфраструктурных комплексов важна техническая совместимость и инфраструктурная прозрачность. Рекомендуется ориентироваться на обеспечение бесшовной интеграции алгоритмических модулей в гетерогенную архитектуру существующих SCADA-платформ и систем сбора, обработки и хранения данных. Достижение данного эффекта предполагает использование стандартных интерфейсов взаимодействия с сенсорными подсистемами (включая специализированные криогенные датчики давления, расхода, уровней ионизированных частиц), а также унификацию форматов данных, минимизирующую необходимость в дорогостоящей переработке инфраструктуры.

Для методов управления многослойными криогенными системами важна модульная композиция и сегментация функционала. Структурирование интеллектуальных модулей машинного обучения по принципу независимых функциональных блоков (предобработки данных, прогнозно-аналитического ядра, системы принятия решений и т.д.) обеспечивает их изолированную отладку, оперативное обновление версий и масштабируемость.

Такой архитектурный подход гарантирует ускоренное внедрение новейших алгоритмических улучшений без нарушения целостности базовой технологической платформы.

В качестве рекомендации предлагается осуществление стандартизации и унификации входных данных. Необходима разработка требований к стандартизации формата, семантики и метрологического обеспечения параметрических данных, используемых для обучения моделей и их дальнейшего функционирования.

В частности, устанавливаются требования к временным рядам параметров, связанных с контролем температурных градиентов и давлений в многоуровневых криогенных контурах, что обеспечивает корректную интерпретацию входной информации моделями машинного обучения.

С экономической точки зрения важна оптимизация вычислительных затрат и эффективное распределение ресурсов. Интеграция интеллектуальных методов в системы с ограниченными вычислительными ресурсами предполагает разработку адаптивных стратегий, таких как внедрение распределенных вычислительных схем, гибридных алгоритмических комплексов, сочетающих легковесные модели начального анализа с более вычислительно дорогими методами для детального прогноза и сложных сценариев. Данная оптимизация позволяет поддерживать заданный уровень производительности при минимизации аппаратных и временных затрат.

Для повышения прозрачности и операционной применимости рекомендуется использовать современные инструменты интерпретации решений алгоритмов машинного обучения (например, SHAP или LIME), которые обеспечивают формирование понятного описания вклада отдельных параметров в итоговый прогноз. Такая интерпретируемость способствует повышению доверия со стороны операторского персонала, а также улучшает управляемость системы в условиях изменяющихся эксплуатационных режимов.

С целью успешной интеграции алгоритмов машинного обучения в системы управления многослойными криогенными объектами необходимо обеспечить кибербезопасность и устойчивость к отказам. Рекомендации фокусируются на необходимости внедрения механизмов защиты данных и непрерывного мониторинга работоспособности интегрированных алгоритмов.

Это подразумевает внедрение мер по защите от несанкционированного доступа, обеспечению устойчивости к аномалиям и разработку процедур своевременной диагностики сбоев, что

критически важно для бесперебойного функционирования криогенных систем. Процесс интеграции предполагает тестирование и пилотные испытания в реальных условиях. Предполагается апробация внедряемых алгоритмов в контексте пилотных испытаний на реальных промышленных объектах, что позволит выявить скрытые ограничения, уточнить параметры адаптации и воспроизвести условия реальной эксплуатации. Полученные результаты станут фундаментом для дальнейшей оптимизации и совершенствования методических рекомендаций.

На основе анализа доступных данных и обобщения накопленного опыта определены конкретные алгоритмические решения:

1. Применение логистической регрессии для классификационных задач первичной диагностики состояния системы с точки зрения обнаружения аномальных режимов.

2. Использование методов случайного леса для оценки взаимосвязей между параметрами и детальных прогнозных оценок, отражающих сложный характер термодинамических процессов.

3. Внедрение градиентных бустинговых алгоритмов для решения задач прогностического анализа при высоконелинейных зависимостях между параметрами в многослойных криогенных контурах.

Предложенные рекомендации охватывают также разработку унифицированных интерфейсных модулей, обеспечивающих двунаправленное взаимодействие с системами реального времени. Они позволяют непрерывно осуществлять мониторинг параметров, оперативную предобработку, а также гибкую интеграцию новых аналитических блоков.

Указанные подходы и решения образуют основу для формирования комплексной интеллектуально-аналитической платформы, которая повышает надежность, отказоустойчивость и эффективность эксплуатации многослойных криогенных систем. Разработанные стандарты и рекомендации находят применение не только в промышленных условиях, но и при управлении специализированными научно-исследовательскими установками и критически важной транспортной инфраструктурой, где требования к точности прогнозирования и устойчивости работы особенно высоки.

ЗАКЛЮЧЕНИЕ

На основе алгоритмов машинного обучения разработана архитектура системы поддержки принятия решений, которая обеспечивает возможность эффективной интеграции с существую-

щими системами управления и адаптации к новым задачам. Главный акцент сделан на применение алгоритмов машинного обучения, что обеспечивает возможность решения задач прогнозирования, анализа и оптимизации параметров работы многослойных криогенных систем. По итогам исследования выработан ряд рекомендаций по интеграции разработанных методов в существующие системы управления:

1. Для технической компатибельности и инфраструктурной прозрачности рекомендуется использовать стандартные интерфейсы взаимодействия с сенсорными подсистемами с унификацией форматов данных, минимизирующей необходимость в дорогостоящей переработке инфраструктуры.

2. Модульная композиция и сегментация функционала позволит ускорить внедрение алгоритмических улучшений без нарушения целостности базовой технологической платформы. С целью обеспечения корректной интерпретации входной информации требуется стандартизация и унификация входных данных.

3. Использование современных инструментов интерпретации решений алгоритмов машинного обучения будет способствовать интерпретируемости и доверию к разработанным моделям.

Результаты исследования могут быть использованы инженерами и исследователями, занимающимися эксплуатацией и проектированием криогенных систем, а также в других областях, где требуется управление сложными техническими системами. Кроме того, предложенные рекомендации могут применяться для разработки новых стандартов по эксплуатации криогенных систем, обеспечивая повышение их безопасности и надежности. Основные положения и выводы исследования могут быть полезны для повышения эффективности эксплуатации криогенных систем, а также для дальнейшего развития методов анализа и прогнозирования в области управления сложными техническими системами.

Авторы заявляют об отсутствии конфликта интересов, требующего раскрытия в данной статье.

The authors declare the absence a conflict of interest warranting disclosure in this article.

ЛИТЕРАТУРА

1. Астраханцева И.А., Котенев Т.Е., Горев С.В. [и др.]. Методы искусственного интеллекта в управлении многослойной криогенной системой с вакуумной изоляцией и азотным экраном. *Современные наукоемкие технологии. Региональное приложение*. 2024. № 1(77). С. 50-59. DOI 10.6060/snt.20247701.0007.
2. Астраханцева И.А., Котенев Т.Е., Горев С.В. [и др.]. Метод градиентного бустинга при прогнозировании управленческих решений в многослойной криогенной системе. *Современные наукоемкие технологии. Региональное приложение*. 2024. № 2(78). С. 50-58. DOI 10.6060/snt.20247802.0007.
3. Бобков С.П., Астраханцева И.А., Галиаскаров Э.Г., Бобкова Е.С. Имитационное моделирование процесса электросинтеза озона. *Современные наукоемкие технологии. Региональное приложение*. 2024. № 2(78). С. 59-67. DOI 10.6060/snt.20247802.0008.
4. Астраханцева И.А., Котенев Т.Е., Горев С.В. [и др.]. Интеграция методов линейной регрессии и случайного леса в системы интеллектуальной поддержки управления криогенными транспортными системами. *Известия высших учебных заведений. Серия: Экономика, финансы и управление производством [Ивэкофин]*. 2024. № 3(61). С. 81-90. DOI 10.6060/ivecofin.2024613.692. – EDN RGESSD.
5. Astrakhantsev R., Chuhno A., Dmukh A. [et al.]. Differences with high probability and impossible differentials for the KB-256 cipher. *Journal of Computer Virology and Hacking Techniques*. 2024. V. 20. N 3. P. 525-531. DOI 10.1007/s11416-024-00532-2. – EDN IQFPUV.

REFERENCES

1. Astrakhantseva I.A., Kotenev T.E., Gorev S.V. [et al.]. Artificial Intelligence Methods in Control of a Multilayer Cryogenic System with Vacuum Insulation and a Nitrogen Screen. *Modern high technology. Regional application*. 2024. N 1(77). P. 50-59. DOI 10.6060/snt.20247701.0007.
2. Astrakhantseva I.A., Kotenev T.E., Gorev S.V. [et al.]. Gradient boosting method for forecasting management decisions in a multilayer cryogenic system. *Modern high technology. Regional application*. 2024. N 2(78). P. 50-58. DOI 10.6060/snt.20247802.0007.
3. Bobkov S.P., Astrakhantseva I.A., Galiaskarov E.G., Bobkova E.S. Simulation modeling of the ozone electrosynthesis process. *Modern high technology. Regional application*. 2024. N 2(78). P. 59-67. DOI 10.6060/snt.20247802.0008. – EDN RFDSCM.
4. Astrakhantseva I.A., Kotenev T.E., Gorev S.V. [et al.]. Integration of linear regression and random forest methods into intelligent control support systems for cryogenic transport systems. *Ivecofin*. 2024. N 3(61). P. 81-90. DOI 10.6060/ivecofin.2024613.692. – EDN RGESSD.
5. Astrakhantsev R., Chuhno A., Dmukh A. [et al.]. Differences with high probability and impossible differentials for the KB-256 cipher. *Journal of Computer Virology and Hacking Techniques*. 2024. V 20. N 3. P. 525-531. DOI 10.1007/s11416-024-00532-2. – EDN IQFPUV.
6. Bobkov S.P., Astrakhantseva I.A., A. A. Gushchin A.A. [et al.]. Using a discrete probabilistic approach for simulating flow tubular reactors. *ChemChemTech [Izv. Vyssh. Uchebn. Zaved. Khim. Khim. Tekhnol.]*. 2025. V. 68. N 2. P. 96-101. DOI 10.6060/ivkkt.20256802.7109. – EDN OWCXJD.

6. Бобков С.П., Астраханцева И.А., Гушин А.А. [и др.]. Использование дискретного вероятностного подхода для моделирования проточных трубчатых реакторов. *Изв. вузов. Химия и хим. технология*. 2025. Т. 68. № 2. С. 96-101. DOI 10.6060/ivkkt.20256802.7109.
7. Sakharova Yu.N., Il'in A.A., Ptitsyna K.O. [et al.]. Thermo-Programmed Reduction of Cobalt Ferrite with Hydrogen. *Russian Journal of General Chemistry*. 2023. V. 93. N 6. P. 1616-1621. DOI 10.1134/s1070363223060373. – EDN JMHKYS.
8. Astrakhantseva I.A., Astrakhantsev R.G., Usoltsev S.D. [et al.]. K-means analysis of spectral properties of BODIPY dye during compression on air - water interface: construction of dataset for effective clustering. *Liquid Crystals and their Application*. 2024. Vol. 24, N 2. P. 43-53. DOI 10.18083/LCAppl.2024.2.43. – EDN CXAIQV.
9. Горев С.В. Особенности проведения судебной экспертизы предметов искусства. Сборник научных трудов вузов России "Проблемы экономики, финансов и управления производством". 2020. № 47. С. 101-104.
10. Зимнуров М.Ф., Астраханцева И.А., Грименицкий П.Н. Системный анализ и оптимизация количественных показателей эффективности в технологических проектах на основе гибких методологий. *Современные наукоемкие технологии. Региональное приложение*. 2023. № 3(75). С. 61-68. DOI 10.6060/snt.20237503.0008. – EDN OYNXHV.
11. Морозов Е.Н., Горев С.В. Математические модели для оптимизации машиночитаемых регулятивных систем. *Известия высших учебных заведений. Серия: Экономика, финансы и управление производством [Ивэкофин]*. 2023. № 4(58). С. 71-78. DOI 10.6060/ivecofin.2023584.666. – EDN LLSUGG.
12. Бобков С.П., Галиаскаров Э.Г. Моделирование процесса теплопроводности с использованием систем клеточных автоматов. *Программные продукты и системы*. 2020. № 4. С. 641-650. DOI 10.15827/0236-235X.132.641-650. – EDN RFIIRL.
13. Astrakhantseva I.A., Astrakhantsev R.G., Mitin A.V. Randomized C/C++ dynamic memory allocator. *Journal of Physics: Conference Series*: 2, Moscow, 01 июля 2021 года. Moscow, 2021. P. 012006. DOI 10.1088/1742-6596/2001/1/012006. – EDN POZQDG.
14. Bobkov S.P., Astrakhantseva I.A. The use of multi-agent systems for modeling technological processes. *Journal of Physics: Conference Series*: 2, Moscow, 01 июля 2021 года. Moscow, 2021. P. 012002. DOI 10.1088/1742-6596/2001/1/012002. – EDN ZXPPKV.
15. Астраханцев Р.Г., Лось А.Б., Мухамадиева Р.Ш. Анализ современных тенденций развития технологии "блокчейн" и цифровых валют. *Вопросы кибербезопасности*. 2019. № 5(33). С. 57-62. DOI 10.21681/2311-3456-2019-5-57-62. – EDN ENCYWG.
16. Telegin F.Y., Karpova V.S., Makshanova A.O. [et al.]. Solvatochromic Sensitivity of BODIPY Probes: A New Tool for Selecting Fluorophores and Polarity Mapping. *International Journal of Molecular Sciences*. 2023. Vol. 24, N 2. P. 1217. DOI 10.3390/ijms24021217. – EDN ZDSWJC.
17. Баландина Е.В., Зеленцова Е.С., Астраханцев Р.Г. Совершенствование методики финансового анализа в рамках судебной финансово-экономической экспертизы. *Известия высших учебных заведений. Серия: Экономика, финансы и управление производством [Ивэкофин]*. 2021. № 2(48). С. 6-16. DOI 10.6060/ivecofin.2021482.528. – EDN RXRRJI.
7. Sakharova Yu.N., Il'in A.A., Ptitsyna K.O. [et al.]. Thermo-Programmed Reduction of Cobalt Ferrite with Hydrogen. *Russian Journal of General Chemistry*. 2023. V. 93. N 6. P. 1616-1621. DOI 10.1134/s1070363223060373. – EDN JMHKYS.
8. Astrakhantseva I.A., Astrakhantsev R.G., Usoltsev S.D. [et al.]. K-means analysis of spectral properties of BODIPY dye during compression on air - water interface: construction of dataset for effective clustering. *Liquid Crystals and their Application*. 2024. V. 24, N 2. P. 43-53. DOI 10.18083/LCAppl.2024.2.43.
9. Gorev S.V. Features of conducting forensic examination of art objects. Collection of scientific papers of Russian universities "Problems of Economics, Finance and Production Management". 2020. N 47. P. 101-104.
10. Zimnurov M.F., Astrakhantseva I.A., Grimenitsky P.N. Systems analysis and optimization of quantitative performance indicators in technological projects based on flexible methodologies. *Modern high technology. Regional application*. 2023. N 3(75). P. 61-68. DOI 10.6060/snt.20237503.0008. – EDN OYNXHV.
11. Morozov E.N., Gorev S.V. Mathematical models for optimization of machine-readable regulatory systems. *Ivecofin*. 2023. N 4(58). P. 71-78. DOI 10.6060/ivecofin.2023584.666. – EDN LLSUGG.
12. Bobkov S.P., Galiaskarov E.G. Modeling the heat conduction process using cellular automata systems. *Software products and systems*. 2020. N 4. P. 641-650. DOI 10.15827/0236-235X.132.641-650. – EDN RFIIRL.
13. Astrakhantseva I.A., Astrakhantsev R.G., Mitin A.V. Randomized C/C++ dynamic memory allocator. *Journal of Physics: Conference Series*: 2, Moscow, 01 июля 2021 года. Moscow, 2021. P. 012006. DOI 10.1088/1742-6596/2001/1/012006. – EDN POZQDG.
14. Bobkov S.P., Astrakhantseva I.A. The use of multi-agent systems for modeling technological processes. *Journal of Physics: Conference Series*: 2, Moscow, July 01, 2021. Moscow, 2021. P. 012002. DOI 10.1088/1742-6596/2001/1/012002. – EDN ZXPPKV.
15. Astrakhancev R.G., Los A.B., Mukhamadiev R.Sh. Analysis of modern trends in the development of blockchain technology and digital currencies. *Cybersecurity Issues*. 2019. N 5(33). P. 57-62. DOI 10.21681/2311-3456-2019-5-57-62. – EDN ENCYWG.
16. Telegin F.Y., Karpova V.S., Makshanova A.O. [et al.]. Solvatochromic Sensitivity of BODIPY Probes: A New Tool for Selecting Fluorophores and Polarity Mapping. *International Journal of Molecular Sciences*. 2023. V. 24, N 2. P. 1217. DOI 10.3390/ijms24021217. – EDN ZDSWJC.
17. Balandina E.V., Zelentsova E.S., Astrakhancev R.G. Improving the methodology of financial analysis in the framework of forensic financial and economic expertise. *Ivecofin*. 2021. N 2(48). P. 6-16. DOI 10.6060/ivecofin.2021482.528. – EDN RXRRJI.
18. Bobkov S.P., Astrakhancev R.G., Pavlova E.A. Study of the structure of flows in technological devices using discrete dynamic models. *Modern high technology. Regional application*. 2024. N 1(77). P. 95-101. DOI 10.6060/snt.20247701.00013. – EDN RZCTJF.
19. Nesterenko A.Yu., Astrakhancev R.G. On one approach to the development of a threshold scheme for electronic signature GOST R 34.10 and its extensions. Algebra, number theory, discrete geometry and multiscale modeling: modern problems, applications and problems of history: Proceedings of the XXI International Conference dedicated to the 85th anniversary of the birth of A.A.

18. **Бобков С.П., Астраханцев Р.Г., Павлова Е.А.** Исследование структуры потоков в технологических аппаратах с использованием дискретных динамических моделей. *Современные наукоемкие технологии. Региональное приложение*. 2024. № 1(77). С. 95-101. DOI 10.6060/snt.20247701.00013. – EDN RZCTJF.
19. **Нестеренко А.Ю., Астраханцев Р.Г.** Об одном подходе к разработке пороговой схемы электронной подписи ГОСТ р 34.10 и ее расширений. Алгебра, теория чисел, дискретная геометрия и многомасштабное моделирование: современные проблемы, приложения и проблемы истории: Материалы XXI Международной конференции, посвящённой 85-летию со дня рождения А.А. Карацубы, Тула, 17–21 мая 2022 года. Тула: Тульский государственный педагогический университет им. Л.Н. Толстого, 2022. С. 170-172. – EDN UWIZHS.
20. **Макшанова А.О., Зимнуров М.Ф., Астраханцева И.А., Астраханцев Р.Г.** Анализ рисков и перспективы использования биометрических технологий в цифровой экономике. Сборник научных трудов вузов России "Проблемы экономики, финансов и управления производством". 2021. № 48. С. 101-104. – EDN MMITGK.
- Karatsuba, Tula, May 17–21, 2022. Tula: Tula State Pedagogical University named after L.N. Tolstoy, 2022. P. 170–172. – EDN UWIZHS.**
20. **Makshanova A.O., Zimnurov M.F., Astrakhantseva I.A., Astrakhantsev R.G.** Risk analysis and prospects for using biometric technologies in the digital economy. Collection of scientific papers of Russian universities "Problems of Economics, Finance and Production Management". 2021. N 48. P. 101-104. - EDN MMITGK.

Поступила в редакцию(Received) 27.03.2025
Принята к опубликованию (Accepted) 24.04.2025