

**МЕТОД ГРАДИЕНТНОГО БУСТИНГА ПРИ ПРОГНОЗИРОВАНИИ
УПРАВЛЕНЧЕСКИХ РЕШЕНИЙ В МНОГОСЛОЙНОЙ КРИОГЕННОЙ СИСТЕМЕ**

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

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), Грименицкий Павел Николаевич (ORCID 0009-0002-3379-8760) 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, grim@isuct.ru

В научной статье исследуется эффективность использования модели градиентного бустинга для прогнозирования управленческих решений в многослойных криогенных системах с использованием датасета из 730 наблюдений. Вводятся дополнительные нелинейные признаки, такие как квадратный корень из произведения уровней и давлений газов (H_e и N_2) и уровень азота равный нулю, что позволило улучшить качество моделирования за счет более корректного учёта взаимодействий переменных. Модель градиентного бустинга показала высокую производительность, что подтверждается значением F1-меры 0,925, указывающей на эффективное сочетание точности и полноты предсказаний модели. Анализ матрицы ошибок показал надёжную способность модели определять состояния, не требующие вмешательства, при минимальном допущении ошибок второго типа, что критически важно для поддержания стабильности системы. В работе была проведена оценка значимости признаков с использованием значений SHAP, которая подтвердила, что уровни и давления газов являются основными драйверами предсказаний модели. Доказывается эффективность использования градиентного бустинга для прогнозирования управленческих решений в криогенных системах. В перспективе дальнейших исследований возможно применение других моделей машинного обучения, таких как нейронные сети или ансамбли алгоритмов, на текущем объеме данных для сравнения и возможного улучшения результатов. Также целесообразно рассмотреть возможность расширения датасета, что позволит строить более сложные модели и обеспечить более точные и надёжные прогнозы.

Ключевые слова: многослойная криогенная система, криогенный контейнер-цистерна, вакуумный экран, жидкий азот, жидкий гелий, теплозащитный экран, вакуумная изоляция, машинное обучение, обучение с учителем, классификация, градиентный бустинг, значимость факторов, полиномиальные признаки

**GRADIENT BOOSTING METHOD IN PREDICTING MANAGEMENT DECISIONS
IN THE MULTILAYER CRYOGENIC SYSTEMS**

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

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 000 0-0001 -9880-2826), Grimenitsky Pavel Nikolaevich (ORCID 0009-0002-3379-8760) Ivanovo State University of Chemical Technology, Ivanovo, Russia. 153000, Ivanovo region, Ivanovo, Sheremetevskyave., 7. E-mail: i.astrakhantseva@mail.ru, kotenev@me.com, gorev@srosov.ru, rgastrakhantsev@gmail.com, grim@isuct.ru

This scientific article seeks to investigate the effectiveness of using a gradient boosting model for predicting managerial decisions in multilayer cryogenic systems using a dataset of 730 observations. Additional nonlinear features are introduced, such as the square root of the product of gas levels and pressures (He and N₂) and a nitrogen level equal to zero, which improves the quality of modeling by more accurately accounting for variable interactions. The gradient boosting model has demonstrated high performance, as evidenced by the F1 score of 0.925, indicating an effective combination of precision and completeness in the predictions made by the model. Error matrix analysis has shown the model's reliability in identifying states that do not require intervention, with minimal occurrence of Type II errors, which is critically important for maintaining the stability of a cryogenic system. The study includes an assessment of feature significance using SHAP values, confirming that gas levels and pressures are the main drivers of the model's predictions. The use of gradient boosting for forecasting managerial decisions in cryogenic systems has been proven based on the efficiency obtained. In terms of future research, the application of other machine learning models such as neural networks or algorithm ensembles on the current data volume for comparison and possible improvement of results is possible. It is also advisable to consider expanding the dataset, which will allow for the construction of more complex models and ensure more accurate and reliable forecasts.

Keywords: multilayer cryogenic system, cryogenic tank container, vacuum screen, liquid nitrogen shield, liquid helium, thermal insulation screen, vacuum insulation, supervised learning, classification, gradient boosting, significance of factors, polynomial features

ВВЕДЕНИЕ

Прогнозирование управленческих решений в многослойных криогенных системах представляет собой многоаспектную проблему, которая базируется на таких факторах как термодинамика, гидродинамика и сложность технической системы [1, 2]. Эффективное управление и эксплуатация криогенных систем в значительной степени зависит от прогнозных моделей, которые способны предвидеть поведение криогенных компонентов в процессе эксплуатации.

Однако сложность и нелинейность криогенных процессов препятствуют разработке надежных методов прогнозирования [2]. Более того, критическая значимость управленческих решений поддержания оптимальной производительности и безопасности многослойных криогенных систем дополнительно добавляет актуальности процессу прогнозирования. Неточность прогнозов приводят к потере криогенного вещества и существенным операционным затратам.

Метод градиентного бустинга представляет собой высокоэффективный алгоритм машинного обучения, который широко применяется в различных областях науки и техники. Этот метод предназначен для оптимизации сложных нелинейных взаимосвязей между входными параметрами и целевыми переменными. Это позволяет учесть факторы, влияющие на динамику многослойных криогенных систем, включая тепловые притоки, кинетическую энергию, химические реакции и механические воздействия. Градиентный бустинг обладает высокой степенью устойчивости

к переобучению и способен эффективно обрабатывать большие объемы данных. Кроме того, он позволяет учитывать взаимодействие между различными переменными и факторами для улучшения точности и достоверности прогноза, что важно в таких условиях, где даже незначительные изменения могут иметь существенное влияние на работу криосистемы.

МЕТОДЫ И МАТЕРИАЛЫ

В настоящем исследовании этот метод машинного обучения применяется для разработки модели прогнозирования управленческих решений в многослойной криогенной системе с вакуумной изоляцией и охлаждением жидким азотом. Она представляет собой инженерно-техническое транспортное сооружение, состоящее из нескольких компонентов, способствующих эффективной изоляции и охлаждению [3, 4].

Основная структура системы включает внутренний сосуд, содержащий криогенный материал (жидкий гелий), окруженный вакуумной камерой для минимизации теплопередачи конвекцией и проводимостью. Между внутренним сосудом и вакуумной камерой располагаются многослойные изоляционные материалы, состоящие из чередующихся слоев отражающего и непроводящего материалов, что существенно снижает теплопередачу излучением. Внешний сосуд системы содержит жидкий азот, который используется для дополнительного охлаждения и обладает температурой кипения около -196°C .

В работе многослойных криогенных систем неконтролируемое преобразование этой энер-

гии может привести к повышению внутренних температур, что негативно сказывается на эффективности и безопасности системы. Управление процессом преобразования кинетической энергии в тепло является ключевым аспектом в обеспечении стабильной работы и поддержания низких температур, необходимых для эффективного функционирования криогенных систем. Поэтому понимание и снижение влияния преобразования кинетической энергии в тепловую является критически важным фактором при разработке и эксплуатации транспортных систем для криогенных материалов [5, 6].

В данном исследовании был использован ряд библиотек для анализа данных, построения моделей машинного обучения и визуализации результатов. Для обработки и анализа данных были использованы библиотеки `pandas` и `pumpru` – инструменты для работы с табличными данными и многомерными массивами соответственно. Для предобработки данных и кодирования категориальных признаков была использована библиотека `sklearn.preprocessing` [7-9].

Она содержит классы, такие как `OneHotEncoder`, который преобразует категориальные признаки в бинарные. Для построения моделей машинного обучения были использованы библиотеки `sklearn.ensemble` и `sklearn.linear_model`. Класс `GradientBoostingClassifier` использовался для реализации модели градиентного бустинга. Для оценки производительности моделей были использованы метрики из модуля `sklearn.metrics`, такие как `confusion_matrix` и `f1_score`. Для визуализации результатов и объяснения прогнозов моделей были использованы библиотеки `shap` и `matplotlib.pyplot`. Для создания новых полиномиальных признаков, включая взаимодействия между признаками использовалась функция `PolynomialFeatures` [10, 11].

АНАЛИЗ ПРЕДМЕТНОЙ ОБЛАСТИ

Для анализа криогенных систем используются статистические методы, методы математического моделирования и машинного обучения. Статистические методы, такие как анализ временных рядов и регрессионный анализ используются для прогнозирования их динамики со временем. Физические моделирования используются для описания основных механизмов работы криогенных систем и оценки их производительности и надежности на основе фундаментальных принципов физики [12-15]. В целях настоящего исследования предлагается использовать машинное обучение для создания прогнозных моделей и учета сложных взаимосвязей между переменными в

системе. В современной области машинного обучения можно выделить четыре основных типа обучения – это обучение с учителем, обучение без учителя, полуавтоматическое обучение и обучение с подкреплением. Обучение с учителем основано на использовании размеченных данных с известными выходными метками для обучения модели. В настоящем исследовании был выбран метод градиентного бустинга.

Он позволяет построить модель, которая учитывает сложные взаимосвязи между входными параметрами и целевыми переменными, такими, как уровень и давление азота и гелия. Градиентный бустинг использует ансамбль деревьев решений для построения прогностических моделей. Основной идеей метода является последовательное построение набора базовых моделей, каждая из которых направлена на улучшение ошибки предыдущей модели [16-18].

Процесс работы градиентного бустинга начинается с построения базовой модели, обычно дерева решений, которая используется для предсказания целевой переменной. Затем вычисляется остаточная ошибка между предсказанными значениями и реальными наблюдениями.

Далее строится следующая модель, которая фокусируется на уменьшении этой остаточной ошибки. Этот процесс повторяется последовательно, при этом каждая новая модель фокусируется на улучшении предыдущих результатов путем "подстройки" или "усиления" сложных для моделируемой зависимости.

Математически градиентный бустинг можно описать как алгоритм оптимизации, который ищет функцию $F(x)$, минимизирующую функцию потерь $L(y, F(x))$, где y – целевая переменная, x – вектор признаков, $F(x)$ – прогноз модели, L – функция потерь. Каждая следующая модель обучается на остатках предыдущей модели, чтобы улучшить прогноз [19-21]. Основным преимуществом градиентного бустинга является его способность к адаптации к сложным структурам данных и обучению на основе ошибок предыдущих моделей.

Это позволяет достигать высокой точности прогнозирования даже в условиях существенной шумности и нелинейности данных.

Кроме того, градиентный бустинг позволяет эффективно учитывать взаимодействие между переменными и автоматически обрабатывать пропущенные значения.

Для реализации градиентного бустинга и анализа многослойной криогенной системы использовался датасет, состоящий из 730 наблюдений.

Каждое наблюдение содержало информацию о характеристиках многослойной криогенной системы, включая дату наблюдения, статус контейнера (находится ли система в пути или в покое), уровень азота, давление азота, уровень гелия и давление гелия.

Кроме того, каждому наблюдению была присвоена целевая переменная y , которая представляла собой управленческое решение для системы – нужно ли оставить систему без действия или требуется ли какое-либо действие (рис. 1).

№ п/п	Дата	Статус контейнера	LI - 01 уровень He	PI-01/PI-03 давление He (psi)	LI-02 уровень N2	PI-02 давление N2 (psi)	Управленческое решение
0	1 14.02.2023	В пути	0	64	0	1	Требуется действие
1	2 14.02.2023	В пути	0	60	0	1	Требуется действие
2	3 14.02.2023	В пути	0,1	2	0	0	Требуется действие
3	4 15.02.2023	В пути	0	67	0	0	Требуется действие
4	5 15.02.2023	В пути	0	60	0	2	Требуется действие
...
722	726 18.12.2023	В пути	8,6	22	44	3,9	Оставить без действий
723	727 18.12.2023	В пути	7,9	6	30	4	Оставить без действий
724	728 18.12.2023	В пути	0,9	94	33	1,5	Оставить без действий
725	729 18.12.2023	В пути	0	60	30	6,9	Оставить без действий
726	730 18.12.2023	В пути	7,5	70	55	9,5	Оставить без действий

Рис. 1 Датасет
Fig. 1 Data set

Для реализации градиентного бустинга и анализа многослойной криогенной системы используются данные об уровне азота и давления в контейнере. Уровень азота напрямую влияет на эффективность теплоизоляции и поддержание температурного баланса. Изменения в уровне азота могут указывать на потери из-за испарения или неэффективности изоляционных материалов, что в свою очередь может привести к снижению охлаждения. Давление азота отражает термодинамическое состояние системы и требует контроля для предотвращения рисков образования конденсата, обледенения или ледяных пробок. Уровень гелия и давление гелия в системе также играют важную роль. Гелий обеспечивает необходимые условия для поддержания сверхнизких температур. Изменения в их уровне или давлении указывают на потери или неэффективность теплообмена. Поддержание определенного давления гелия необходимо для гарантированной безопасности и эффективности работы системы. Информация о статусе контейнера позволяет адаптировать параметры системы для обеспечения оптимальных условий покоя или транспортировке криогенных материалов. Это не только снижает риск потери материала из-за утечек, но и обеспечивает безопасность и эффективность работы всей криогенной системы.

Анализируемый набор данных по уровень азота (N2) в системе характеризуется ненормальным распределением. Значительное количество наблюдений показывает нулевой уровень азота, что указывает на данные, собранные при запуске криосистем (рис. 2). Такое распределение существенно влияет на эффективность применения алгоритмов машинного обучения, особенно тех, которые предполагают нормальность данных, в частности алгоритмы классификации. Ненормальное распределение приводит к искажению результатов прогноза, если не применяются специальные методы предварительной обработки данных, такие как нормализация или стандартизация.

В результате этого было принято решение в исходном наборе данных DataFrame `data` реализовать процесс добавления нового столбца `LI-02 уровень N2 = 0`, который предназначен для выделения нулевых значений в столбце `LI-02 уровень N2`. Для каждого элемента этого столбца применяется функция, которая возвращает значение 1, если исходное значение равно нулю, и значение 0 в противном случае.

Такая трансформация помогает более точной настройке моделей машинного обучения, поскольку такие записи влияют на обучение и качество моделирования.




Рис. 2 Распределение данных в дата сете по уровню азота
Fig. 2 Distribution of data in the dataset by nitrogen level

В рамках предварительной обработки данных была проведена операция генерации новых признаков на основе взаимодействий между параметрами, существующими в наборе данных, с использованием метода полиномиальной регрессии. Для этого применим класс `PolynomialFeatures` из библиотеки `scikit-learn` с активированным параметром `interaction_only=True`. Это позволяет генерировать признаки, которые представляют собой произведения исходных признаков без включения их степеней. Были созданы новые признаки путем вычисления произведений между уровнем гелия ("LI-01 уровень He") и его давлением ("PI-01/PI-03 давление He (psi)"), а также аналогичных взаимодействий для азота ("LI-02 уровень N2" и "PI-02 давление N2 (psi)"). Полученные признаки были дополнительно трансформированы путем извлечения квадратного корня. Такие операции способствуют улучшению линейности взаимосвязей и повышению эффективности последующих аналитических моделей.

Далее эти новые признаки были интегрированы в исходный набор данных путем конкатенации, то есть соединения двух и более последовательностей или структур данных в одну. После чего была выполнена операция очистки данных от пропущенных значений и сброса индексации для обеспечения консистентности структуры данных. Эти операции не только улучшили информативность набора данных за счет включения взаимодействий между параметрами, но и подготовили его к более эффективному применению в методах машинного обучения. Учет взаимодействий между признаками влияет на точность прогнозных моделей.

Таким образом, в рамках предобработки данных с целью улучшения предсказательной способности модели были созданы дополнительные признаки на основе существующего дата сета. Этот процесс направлен на выявление потенциальных нелинейных взаимосвязей между различными предикторами и целевой переменной - управленческим решением для многослойной криосистемы. В результате такого нелинейного преобразования предикторов были добавлены следующие новые признаки: квадратный корень из произведения давления и уровня гелия, квадратный корень из произведения уровня и давления азота, уровень азота равный нулю.

РЕЗУЛЬТАТЫ И ДИСКУССИИ

В рамках исследования была разработана модель классификации с использованием алгоритма градиентного бустинга, реализованного с помощью класса `GradientBoostingClassifier` из библиотеки `scikit-learn`. Модель была сконфигурирована с параметрами 200 деревьев решений и максимальной глубиной дерева 3. Эти параметры были выбраны с целью достижения оптимального баланса между точностью предсказаний и вычислительной эффективностью. В процессе оптимизации модели градиентного бустинга для криогенных систем выявлено, что количество деревьев и их глубина влияют на количество ошибок. Параметры, отличные от 200 деревьев и максимальной глубины 3, приводили к увеличению ошибок.

Меньшее число деревьев и меньшая глубина не захватывают сложность данных, в то время как избыточное увеличение этих параметров делает модель чрезмерно адаптированной к обучающей выборке.

Оптимальные параметры были выбраны для достижения баланса между точностью и вычислительной эффективностью, снижая риск недообучения и переобучения, что обеспечивает стабильность и надежность системы. Первоначально модель подверглась обучению на тренировочном наборе данных. После чего была оценена на тестовом наборе. Для оценки качества классификации использовалась метрика F1-меры, которая рассчитывается усреднением по всем классам ('macroaverage'). Это позволяет учесть влияние несбалансированности классов. Значение F1-меры равной 0,925 говорит о высокой эффективности бинарной классификационной модели в управлении многослойной криосистемой.

Макро-усредненная F1-мера рассчитывает путем отдельного вычисления F1-меры для каждого класса с последующим их усреднением.

Такой подход обеспечивает равное внимание к каждому классу, что критически важно в условиях несбалансированных классов, представленных дата сете. Высокий показатель F1-меры свидетельствует о том, что модель обладает как высокой точностью, так и высокой полнотой в процессе идентификации состояний многослойной криосистемы.

Точность модели означает её способность корректно определять только релевантные случаи в каждом классе, в то время как полнота отражает способность обнаруживать все релевантные случаи в каждом классе. Модель градиентного бустинга успешно минимизирует количество ложных срабатываний и обеспечивает высокую чувствительность к действительно требующим внимания состояниям в криосистеме. Для визуализации результатов классификации была использована матрица ошибок, созданная с помощью функции 'confusion_matrix' библиотеки 'scikit-learn' (рис. 3).




Рис. 3. Матрица ошибок для модели бинарной классификации
Fig. 3. Confusion Matrix for Binary Classification Model

Матрица ошибок показывает результаты классификации модели машинного обучения для двух классов. Из 145 случаев, когда истинная метка была 0 (управленческое решение по криосистеме "Не требует действий"), модель правильно предсказала 137 случаев, не допустив ни одной ошибки ложноположительного результата. Из 8 случаев, когда истинная метка была 1 (управленческое решение по системе "Требует действия"), модель правильно предсказала только 6 случаев, допустив 2 ошибки ложноотрицательного результата. Эти результаты показывают высокую специфичность модели. Она эффективно идентифицировала большинство случаев класса "не требует

действий". Это указывает на надежность модели в предотвращении ложноположительных решений.

Для оценки относительной значимости признаков в предиктивной модели градиентного бустинга был применён метод SHAP (SHapleyAdditiveex Planations).

Этот метод позволяет интерпретировать вклад каждого признака в прогнозируемый результат модели на основе теории игр (концепции значений Шепли). Концепция предлагает метод справедливого распределения общего выигрыша или стоимости между участниками на основе их вклада в всевозможные коалиции с обеспечением эффективности, симметрии и справедливости в вознаграждении.

Для расчета значений SHAP была использована реализация `TreeExplainer` из библиотеки SHAP, предназначенная для деревьев решений и ансамблей деревьев, таких как градиентный бустинг. Объект `TreeExplainer` был инициализирован с параметрами обученной модели градиентного бустинга и названиями признаков, что обеспечило точное отображение данных в анализе.

Далее для тестового набора данных были вычислены значения SHAP с помощью метода

`shap_values`, которые представляют величину влияния каждого признака на каждое предсказание модели. Для визуализации и сравнения вклада признаков была создана столбчатая диаграмма, отображающая нормализованные значения SHAP. Нормализация выполнена путём деления значений SHAP на сумму средних абсолютных значений по всем признакам, что позволило представить относительный вклад каждого признака в магнитуду выходных значений модели (рис. 4).

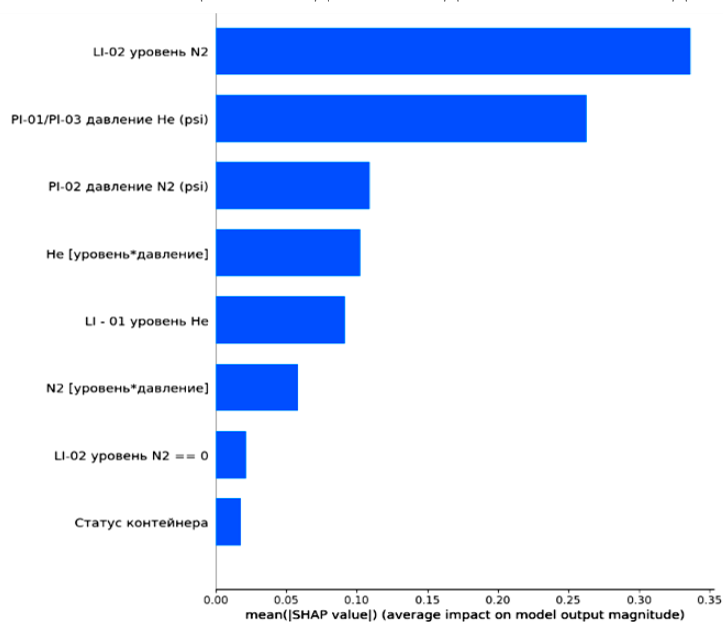


Рис. 4 Значимость признаков в модели градиентного бустинга
Fig. 4 Feature Importance in Gradient Boosting Model

Наибольшее влияние на модель оказывает признак уровня азота в системе (LI-02 уровень N2). Это указывает на то, что колебания в уровне азота играют ключевую роль в процессе принятия решений моделью, подчеркивая значимость мониторинга данного параметра для оптимизации работы криосистемы. Следующим по значимости признаком является давление гелия ("PI-01/PI-03 давление He (psi)"). Значительное влияние этого параметра подчеркивает важность контроля за давлением гелия для обеспечения стабильности и безопасности системы.

Дополнительно сгенерированные полиномиальные признаки (квадратный корень из произведения давления и уровня гелия, квадратный корень из произведения уровня и давления азота) также вносят вклад в модель, но в меньшей степени. Признаки статуса контейнера и уровня азота, равный нулю имеют наименьшее влияние на предсказания, что может свидетельствовать о меньшей релевантности этих параметров в контексте текущих условий моделирования.

Таким образом, обученная модель градиентного бустинга является надежным инструментом мониторинга и контроля многослойных криосистем, что важно в условиях точного и эффективного реагирования на аномалии для предотвращения нежелательных последствий в критически важных операциях.

ЗАКЛЮЧЕНИЕ

В настоящем исследовании проведен анализ использования модели градиентного бустинга для прогнозирования управленческих решений в многослойной криогенной системе на датасете из 730 наблюдений. В исследовании были введены дополнительные нелинейные признаки, такие как корень квадратный из произведений уровней и давлений газов (He и N2), что позволило улучшить качество моделирования за счет учета взаимодействий между переменными. Модель градиентного бустинга показала высокую производительность, что подтверждается значением F1-меры 0.925, что указывает на эффективное сочетание точности и полноты предсказаний модели.

Анализ матрицы ошибок выявил высокую способность модели идентифицировать «не требующие действий» состояния, при этом минимально допуская ошибки типа II (ложноотрицательных результатов), что критически важно для поддержания стабильности криогенных систем.

Дополнительно было проведено исследование значимости признаков с использованием значений SHAP, которое показало, что уровни и давления газов являются ключевыми драйверами предсказаний модели. Градиентный бустинг подтвердил свою высокую эффективность в задачах прогнозирования управленческих решений криогенных систем.

В перспективе дальнейших исследований имеется возможность использования других моделей машинного обучения, таких как нейронные сети или ансамбли различных алгоритмов, на текущем объеме данных для сравнения и возможного улучшения результатов. Также имеет смысл рассмотреть возможность расширения существующего текущего датасета, что позволит строить более сложные модели и обеспечить более точные и надежные прогнозы.

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. **Филин Н.В., Буланов А.Б.** Жидкостные криогенные системы. Л.: Машиностроение, Ленингр. отд-ние, 1985. 247 с.
2. **Архаров А.М., Беляков В.П., Микулин Е.И. и др.** Криогенные системы: Учебник для вузов по курсу «Криогенная техника». М.: Машиностроение, 1987. 536 с.
3. **Микулин Е.И.** Криогенная техника. М.: Машиностроение, 1969. 272 с.
4. **Баранов А.Ю., Соколова Е.В.** Хранение и транспортировка криогенных жидкостей. Часть 1: Учебное пособие. СПб.: Университет ИТМО, 2017. 95 с.
5. **Van Sciver S.W.** (2012) Helium Cryogenics. Springer Science, New York, 470. <http://dx.doi.org/10.1007/978-1-4419-9979-5>
6. **Гордина Н.Е., Мельников А.А., Гусев Г.И., Гуцин А.А., Румянцев Р.Н., Астраханцева И.А.** Использование механохимической и плазмохимической обработок при синтезе каталитических систем на основе вермикулита и оксихлорида циркония. Изв. вузов. Химия и хим. технология. 2022. Т. 65. Вып. 5. С. 43–57. DOI 10.6060/ivkkt.20226505.6612. – EDN KDQEVD.
7. Учебник по машинному обучению. Режим доступа: <https://education.yandex.ru/handbook/ml>.
8. **Breiman L., Friedman J., Stone C.J., & Olshen R.A.** (1984). "Classification and Regression Trees". CRC press.
9. **Морозов Е.Н., Горев С.В.** Математические модели для оптимизации машиночитаемых регулятивных систем. *Известия высших учебных заведений. Серия: Экономика, финансы и управление производством.* 2023. № 4(58). С. 71-78. DOI 10.6060/ivecofin.2023584.666. – EDN LLSUGG.
10. **Murphy K.P.** (2012). "Machine Learning: A Probabilistic Perspective". MIT Press.
11. **Ho T.K.** (1995). "Random Decision Forests". Proceedings of the 3rd International Conference on Document Analysis and Recognition, Montreal, QC, 14-16.
12. **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.
13. **Астраханцева И.А., Горев С.В., Астраханцев Р.Г.** Системный подход к анализу фрактальной природы сложных технических систем. *Известия высших учебных заведений. Серия: Экономика, финансы и управление производством.* 2023. № 3(57). С. 89-97. DOI 10.6060/ivecofin.2023573.657. – EDN PSPGBG.

REFERENECES

1. **Filin N.V., Bulanov A.B.** Liquid Cryogenic Systems. Leningrad: Mashinostroenie, Leningrad Division, 1985. 247 p.
2. **Arkharov A.M., Belyakov V.P., Mikulin E.I. et al.** Cryogenic Systems: Textbook for Universities on the Course "Cryogenic Engineering". Moscow: Mashinostroenie, 1987. 536 p.
3. **Mikulin E.I.** Cryogenic Engineering. Moscow: Mashinostroenie, 1969. 272 p.
4. **Baranov A.Yu., Sokolova E.V.** Storage and Transportation of Cryogenic Liquids. Part 1: StudyGuide. St. Petersburg: ITMO University, 2017. 95 p.
5. **Van Sciver S.W.** (2012) Helium Cryogenics. Springer Science, New York, 470. Available: <http://dx.doi.org/10.1007/978-1-4419-9979-5>
6. **Gordina N.E., Melnikov A.A., Gusev G.I. [et al.].** Mechanochemical and plasmachemical processing in the synthesis of catalytic systems based on vermiculite and zirconium oxychloride. *Chem Chem Tech.* 2022. V. 65. N 5. P. 43-57. DOI 10.6060/ivkkt.20226505.6612. – EDN KDQEVD.
7. Textbook on Machine Learning. Available:<https://education.yandex.ru/handbook/ml>.
8. **Breiman L., Friedman J., Stone C.J., & Olshen R.A.** (1984). "Classification and Regression Trees". CRC Press.
9. **Morozov E.N., Gorev S.V.** Mathematical Models for Optimizing Machine-Readable Regulatory Systems. *Ivecofin.* 2023. N 4(58). P. 71-78. DOI 10.6060/ivecofin.2023584.666.
10. **Murphy K.P.** (2012). "Machine Learning: A Probabilistic Perspective". MIT Press.
11. **Ho T.K.** (1995). "Random Decision Forests". Proceedings of the 3rd International Conference on Document Analysis and Recognition, Montreal, QC, 14-16.
12. **Zimnurov M.F., Astrakhantseva I.A., Grimenitsky P.N.** System Analysis and Optimization of Quantitative Performance Indicators in Technological Projects Based on Flexible Methodologies. *Modern High-Tech Technologies. Regional Supplement.* 2023. N 3(75). P. 61-68. DOI 10.6060/snt. 20237503.0008. – EDN OYNXHV.
13. **Astrakhantseva I.A., Gorev S.V., Astrakhantsev R.G.** Systematic Approach to the Analysis of the Fractal Nature of Complex Technical Systems. *Ivecofin.* 2023. N 3(57). P. 89-97. DOI 10.6060/ivecofin.2023573.657. – EDN PSPGBG.
14. **Bobkov S.P., Astrakhantseva I.A.** Application of an Agent-Based Approach to Modeling Heat Conduction Processes. *Bulletin of the Ivanovo State Power Engineering University.* 2022. N 2. P. 58-66. DOI 10.17588/2072-2672.2022.2.058-066.

14. **Бобков С.П., Астраханцева И.А.** Применение агентного подхода для моделирования процессов теплопроводности. *Вестник Ивановского государственного энергетического университета*. 2022. № 2. С. 58-66. DOI 10.17588/2072-2672.2022.2.058-066. – EDN RWGSSW.
15. **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.
16. **Астраханцева И.А., Бобков С.П.** Дискретная стохастическая модель гидродинамики потока. *Моделирование систем и процессов*. 2023. Т. 16, № 2. С. 7-14. DOI 10.12737/2219-0767-2023-16-2-7-14.
17. **Астраханцева И.А., Горев С.В., Астраханцев Р.Г.** Фрактальный анализ в оценке эффективности и надежности сложных технических систем. *Современные наукоемкие технологии. Региональное приложение*. 2023. № 4(76). С. 60-68. DOI 10.6060/snt.20237604.0008. – EDN NBDYHR.
18. **Морозов Е.Н., Горев С.В.** Математические модели для оптимизации машиночитаемых регулятивных систем. *Известия высших учебных заведений. Серия: Экономика, финансы и управление производством*. 2023. № 4(58). С. 71-78. DOI 10.6060/ivecofin.2023584.666. – EDN LLSUGG.
19. **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.
20. **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.
21. **Бобков С.П., Астраханцева И.А., Галиаскаров Э.Г.** Применение системного подхода при разработке математических моделей. *Современные наукоемкие технологии. Региональное приложение*. 2021. № 1(65). С. 66-71. DOI 10.6060/snt.20216501.0008. – EDN KOXZWY.
15. **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.
16. **Astrakhantseva I.A., Bobkov S.P.** Discrete Stochastic Model of Flow Hydrodynamics. *Modeling of Systems and Processes*. 2023. Vol. 16, N 2. P. 7-14. DOI 10.12737/2219-0767-2023-16-2-7-14. – EDN BYGGKR.
17. **Astrakhantseva I.A., Gorev S.V., Astrakhantsev R.G.** Fractal Analysis in Assessing the Efficiency and Reliability of Complex Technical Systems. *Modern High-Tech Technologies. Regional Supplement*. 2023. N 4(76). P. 60-68. DOI 10.6060/snt.20237604.0008. – EDN NBDYHR.
18. **Morozov E.N., Gorev S.V.** Mathematical Models for Optimizing Machine-Readable Regulatory Systems. *Ivecofin*. 2023. N 4(58). P. 71-78. DOI 10.6060/ivecofin.2023584.666.
19. **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.
20. **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.
21. **Bobkov S.P., Astrakhantseva I.A., Galiaskarov E.G.** Application of a Systems Approach in the Development of Mathematical Models. *Modern High-Tech Technologies. Regional Supplement*. 2021. N 1(65). P. 66-71. DOI 10.6060/snt.20216501.0008. – EDN KOXZWY

Поступила в редакцию 15.03.2024
Принята к опубликованию 06.05.2024

Received 15.03.2024
Accepted 06.05.2024