

**МОДЕЛИ И АЛГОРИТМЫ ИНТЕЛЛЕКТУАЛЬНОГО УПРАВЛЕНИЯ
МНОГОСЛОЙНОЙ КРИОГЕННОЙ СИСТЕМОЙ****И.А. Астраханцева, С.В. Горев**

Ирина Александровна Астраханцева (ORCID 0000-0003-2841-8639)*,
Сергей Владимирович Горев (ORCID 0000-0002-4370-9533)
Ивановский государственный химико-технологический университет,
г. Иваново, Россия. 153000, Ивановская область, г. Иваново, пр. Шереметевский, д. 7.
E-mail: i.astrakhanseva@mail.ru*, gorev@srosov.ru

Разработаны модели и алгоритмы интеллектуальной поддержки принятия решений для управления многослойной криогенной системой при транспортировке сжиженных газов. Предложен алгоритм формирования признакового пространства, включающий оператор преобразования признаков, отображающий исходное пятимерное пространство сенсорных измерений в расширенное восьмимерное пространство на основе физических соотношений между параметрами контролируемых сред. Разработан алгоритм интеллектуальной поддержки принятия решений, включающий модель классификации состояний на расширенном признаковом пространстве и алгоритм представления результатов с декомпозицией вклада каждого признака в решение модели. Разработана функциональная модель системы поддержки принятия решений, реализующая супервизорную архитектуру управления с механизмом адаптации модели на эксплуатационных данных и двухкритериальной валидацией. Экспериментальная оценка на данных парка из 12 криогенных контейнеров за 18 месяцев эксплуатации показала повышение F1-меры классификации состояний с 0,46 до 0,89, сокращение времени реакции оператора с 204 до 2,3 минуты и снижение доли ложных срабатываний с 4,9% до 0,6%.

Ключевые слова: многослойная криогенная система, интеллектуальная поддержка принятия решений, классификация состояний, признаковое пространство, машинное обучение, встраиваемые системы, адаптация модели.

**MODELS AND ALGORITHMS OF INTELLIGENT CONTROL
OF A MULTILAYER CRYOGENIC SYSTEM****I.A. Astrakhanseva, S.V. Gorev**

Irina Aleksandrovna Astrakhanseva (ORCID 0000-0003-2841-8639) *,
Sergey Vladimirovich Gorev (ORCID 0000-0002-4370-9533)
Ivanovo state university of chemistry and technology
Ivanovo, Russia. 153000, Ivanovo region, Ivanovo, Sheremetevsky ave., 7.
E-mail: i.astrakhanseva@mail.ru*, gorev@srosov.ru

Models and algorithms for intelligent decision support in multilayer cryogenic system control during liquefied gas transportation are developed. A feature space formation algorithm is proposed, including a feature transformation operator that maps the original five-dimensional sensor measurement space into an extended eight-dimensional space based on physical relationships between controlled medium parameters. An intelligent decision support algorithm is developed, incorporating a classification model on the extended feature space and a result presentation algorithm with decomposition of each feature's contribution to the model decision. A functional model of the decision support system is developed, implementing a supervisory control architec-

ture with a model adaptation mechanism on operational data and dual-criteria validation. Experimental evaluation on data from a fleet of 12 cryogenic containers over 18 months of operation showed an increase in classification F1-score from 0.46 to 0.89, a reduction in operator response time from 204 to 2.3 minutes, and a decrease in false alarm rate from 4.9% to 0.6%.

Keywords: multilayer cryogenic system, intelligent decision support, state classification, feature space, machine learning, embedded systems, model adaptation.

Для цитирования:

Астраханцева И.А., Горев С.В. Модели и алгоритмы интеллектуального управления многослойной криогенной системой. Современные наукоёмкие технологии. Региональное приложение. 2026. № 2. С. 60-69. DOI: 10.6060/snt.20268602.07

For citation:

Astrakhantseva I.A., Gorev S.V. Models and algorithms for intelligent control of a multilayer cryogenic system. Modern high technology. Regional application. 2026. N 2. P. 60-69. DOI: 10.6060/snt.20268602.07

ВВЕДЕНИЕ

Многослойная криогенная система (МКС) представляет собой сложную техническую систему, предназначенную для транспортировки сжиженных газов при температурах вблизи абсолютного нуля. Конструктивно система включает внутренний резервуар с жидким гелием (4,2 К), промежуточный экранирующий слой жидкого азота (77 К) и вакуумную изоляцию. Азотный экран является ключевым элементом теплозащиты: его потеря приводит к увеличению теплопритока к гелиевому контуру на два порядка, что вызывает интенсивное испарение продукта. Центральной задачей оперативного управления МКС при транспортировке является своевременное определение необходимости долива жидкого азота.

Управление МКС осуществляется с помощью бортового контроллера на базе микропроцессора STM32, размещенного на раме контейнера-цистерны. Контроллер получает данные от пяти датчиков арматурного узла (уровень и давление гелия, уровень и давление азота, статус контейнера), однако вычислительные ресурсы существенно ограничены: объем памяти составляет 256 КБ, допустимое время обработки данных не превышает 50 мс, постоянный канал связи с диспетчерским центром отсутствует [1, 2]. Эти ограничения исключают применение глубоких нейронных сетей, методов автоматической генерации признаков и иных ресурсоемких алгоритмов, требующих графических процессоров или облачных вычислений.

Существующий подход к определению необходимости долива основан на неформализованной процедуре визуального контроля показаний приборов с последующей экспертной оценкой, выполняемой дистанционно без автоматизи-

рованной обработки информации. Такой подход не учитывает совместную динамику параметров контролируемых сред и не обеспечивает количественного обоснования принимаемых решений [3].

Теоретическими основами криогенной техники и физикой криогенных процессов занимались Архаров А.М. [4], Беляков В.П. [5], Van Sciver S.W. [6]. Вопросы теплопередачи в многослойных системах изоляции исследовались Зарубиным В.С. и Кувыркиным Г.Н. [7]. Применение методов машинного обучения к криогенным техническим системам исследовали Tilaro F., Bradu B., Gonzalez-Berges M. [8] (обнаружение аномалий в криогенных системах Большого адронного коллайдера), Kim M., Seong H., Kim D. [9] (прогностика криогенного оборудования на основе глубокого обучения), Saha S.K., Prasad G. [10] (предиктивное обслуживание криогенных насосов). Теоретические основы обработки информации в технических системах развивались в работах Shannon C.E. [11], Советова Б.Я. [12], Новикова Д.А. [13]. Подходы к интеграции физических знаний в модели машинного обучения предложены Raissi M. и Karniadakis G.E. [14]. Вопросы интерпретируемости моделей рассматривались в работах Lundberg S.M. и Lee S.-I. [15]. Развертыванием моделей на встраиваемых системах занимались Warden P. и Situnayake D. [16].

Вместе с тем в известных работах не решена задача формирования признакового пространства с учетом физики процессов теплопереноса для встраиваемых систем с ограниченными ресурсами. Не разработаны алгоритмы представления результатов классификации, обеспечивающие интерпретируемость и переход к верифицируемому управленческому решению оператора. Отсутствуют модели системы под-

держки принятия решений, формализующие полный цикл обработки информации от сбора данных до формирования управленческого решения с механизмом адаптации на эксплуатационных данных.

Целью настоящей статьи является разработка моделей и алгоритмов интеллектуальной поддержки принятия решений для управления многослойной криогенной системой. Основные результаты работы состоят в следующем. Разработан алгоритм формирования признакового пространства с оператором преобразования признаков на основе физических соотношений между параметрами контролируемых сред. Разработан алгоритм интеллектуальной поддержки принятия решений, включающий модель классификации состояний и алгоритм представления результатов. Разработана функциональная модель системы поддержки принятия решений с механизмом адаптации.

МАТЕРИАЛЫ И МЕТОДЫ

Авторами разработана математическая модель классификации состояний МКС, в которой задача определения необходимости долива формализована как

$$\hat{Y} = f(X; \theta; \Psi), \quad (1)$$

где $X \in R^M$ - вектор признаков, $f(\cdot; \theta)$ - решающее правило с настраиваемыми параметрами θ , Ψ - вектор физико-технических ограничений встраиваемой системы. Введение вектора Ψ в формальную постановку задачи является авторским решением, расширяющим стандартную архитектуру модели классификации. Требования к алгоритму, формализованные через Ψ , включают: время обработки ≤ 50 мс, объем модели ≤ 256 КБ, полнота $\geq 0,95$ и обязательная интерпретируемость результатов.

Задача классификации формализована как задача многокритериальной оптимизации:

$$\theta^* = \operatorname{argmin} R_{emp}(f) \text{ при ограничениях } \Psi, \quad (2)$$

где R_{emp} - эмпирический риск.

Введена асимметричная функция потерь, отражающая различие последствий ошибок первого и второго рода:

$$L(y, \hat{y}) = \alpha \cdot FN + \beta \cdot FP. \quad (3)$$

Анализ показал, что потеря продукта вследствие несвоевременного долива азота на два порядка превышает издержки от ложной тревоги ($\alpha/\beta \approx 100$), что обосновывает требование $Recall \geq 0,95$ из вектора Ψ .

Задача формирования признакового пространства формализована через введение оператор

преобразования признаков Φ в общем виде:

$$\Phi: R^n \rightarrow R^M, M > n, \quad (4)$$

с требованием повышения разделимости:

$$J(\Phi(X)) > J(X), \quad (5)$$

где J - мера линейной разделимости. Задача сформулирована как оптимизационная:

$$\Phi^* = \operatorname{argmax} J(\Phi) \text{ при ограничениях } \Psi. \quad (6)$$

Для оценки вклада признаков применена аддитивная декомпозиция решений модели [15]:

$$f(X) = \varphi_0 + \sum_j \varphi_j, \quad (7)$$

где φ_0 - базовое значение модели, φ_j - вклад j -го признака.

Механизм адаптации модели использует двойной критерий валидации:

$$F1(f_{new}) \geq F1(f_{old}) - \delta \text{ и } Recall(f_{new}) \geq \tau, \quad (8)$$

где $\delta = 0,05$, $\tau = 0,95$. Двойной критерий обусловлен тем, что при асимметрии последствий ошибок недопустимо повышение F1 за счет точности при снижении полноты.

Экспериментальные данные получены от парка из 12 криогенных контейнеров за 18 месяцев промышленной эксплуатации. Выборка содержит записи показаний пяти датчиков, сопоставленные с журналом фактических доливов азота. Дисбаланс классов составляет 17,6 к 1 (штатные рейсы существенно преобладают над рейсами, требующими долива). Качество моделей оценивалось методом стратифицированной пятикратной кросс-валидации. Статистическая значимость различий проверялась критерием Вилкоксона для связанных выборок.

РЕЗУЛЬТАТЫ

Предложенный алгоритм формирования признакового пространства включает три этапа (рис. 1).

На первом этапе выполнена предобработка данных по формализованному пятишаговому регламенту: удалены технические дубликаты, исключены записи периодов технического обслуживания, отсеяны отказы датчиков методом межквартильного размаха (ГОСТ Р 8.736-2011, ISO 5725-6:2002), удалены записи переходных режимов после долива и проведена экспертная верификация на непротиворечивость.

На втором этапе выполнено конструирование производных признаков. Экранирующий слой жидкого азота теряет защитные свойства скачкообразно при достижении критического уровня. Этот пороговый эффект формализован бинарным индикатором:

$$x_6 = I(L_{N_2} \leq \delta). \quad (9)$$




Рис. 1. Алгоритм формирования признакового пространства
Fig. 1. Feature space formation algorithm

Разработано авторами

Термодинамическое состояние гелиевого контура описывается соотношением $PV = nRT$, откуда произведение давления на уровень заполнения характеризует запас энергии среды:

$$x_7 = \sqrt{P_{He} \cdot L_{He}}. \quad (10)$$

Аналогично для экранирующего слоя:

$$x_8 = \sqrt{P_{N_2} \cdot L_{N_2}}. \quad (11)$$

Оператор $\Phi: R^5 \rightarrow R^8$ сохраняет пять исходных параметров и добавляет три сконструированных.

На третьем этапе проведена количественная валидация вклада сконструированных признаков. По обучающей выборке вычислены средние абсолютные вклады каждого признака (табл. 1).

Три производных признака обеспечивают 78% суммарного вклада, что подтверждает обоснованность выбранных конструкций. При неудовлетворительном результате валидации алгоритм предусматривает возврат к анализу физики процесса и пересмотр конструкций, что обеспечивает

замкнутость цикла формирования признакового пространства.

На основе вектора Ψ проведен отбор допустимых моделей машинного обучения. Отобраны три модели, удовлетворяющие всем элементам вектора Ψ (табл. 2).

Стандартное отклонение $\sigma = 0,021$ ($CV = 2,3\%$) соответствует зоне высокой устойчивости. Статистическая значимость различий между случайным лесом и логистической регрессией подтверждена критерием Вилкоксона ($W = 15$, $p = 0,031 < 0,05$). Различие между случайным лесом и градиентным бустингом незначимо ($p > 0,5$), что свидетельствует о достижении предела качества ансамблевыми моделями на данной выборке. Случайный лес выбран в качестве базовой модели благодаря меньшей чувствительности к порядку обхода деревьев, что упрощает детерминированное воспроизведение результатов на контроллере [17].

Таблица 1

Вклад признаков в решения модели (средние абсолютные значения)
Table 1. Feature contributions to model decisions (mean absolute values)

Признак	Обозначение	Средний $ \phi $	Доля
Интегральный параметр N_2	x_8	0,420	54%
Интегральный параметр He	x_7	0,280	36%
Индикатор критического уровня	x_6	0,080	10%
Итого производные	$x_6 + x_7 + x_8$	0,780	78%

Разработано авторами

Сравнение моделей на R^8 (кросс-валидация)
Table 2. Model comparison on R^8 (cross-validation)

Модель	F1	$\sigma(F1)$	Precision	Recall
Логистическая регрессия	0,653	0,087	0,512	0,901
Случайный лес	0,925	0,021	0,982	0,876
Градиентный бустинг	0,925	0,024	0,978	0,879

Разработано авторами

Таблица 2




Рис. 2. Алгоритм интеллектуальной поддержки принятия решений

Fig. 2. Intelligent decision support algorithm

Разработано авторами

Разработан алгоритм интеллектуальной поддержки принятия решений, включающий модель классификации состояний и алгоритм представления результатов (рис. 2).

Модель классификации построена на расширенном признаковом пространстве R^8 и оптимизирована с учетом двух особенностей данных. Дисбаланс классов 17,6 к 1 компенсирован взвешиванием наблюдений обратно пропорционально частоте класса. Асимметрия последствий ошибок ($\alpha/\beta \approx 100$) учтена через настройку порога принятия решения и целевую метрику, отдающую приоритет полноте. Гиперпараметры оптимизированы при стратифицированной пятикратной кросс-валидации с целевой F1-мерой для миноритарного класса.

Алгоритм представления результатов обеспечивает формирование интерпретируемой рекомендации для оператора. Полная аддитивная декомпозиция на бортовом контроллере невозможна, поскольку требует перебора 2^M коалиций признаков. Разработан алгоритм упрощенного представления, адаптированный к ресурсам встраиваемого контроллера. Контроллер определяет степень отклонения каждого из восьми параметров от эталонного диапазона, ранжирует параметры по величине отклонения и формирует текстовое объяснение по шаблону, связывающему отклонения с физическим смыслом. Результат классификации $\hat{Y}$, апостериорная вероятность $P(Y = 1 | X)$ и перечень параметров, определивших решение модели с указанием величины их вклада, передаются на планшет оператора. В отличие от существующего ручного управления, при котором оператор принимает решение на ос-

нове субъективной оценки показаний датчиков без автоматизированной обработки информации, алгоритм формирует информационную основу для принятия управленческого решения по результатам совместного анализа всех параметров расширенного признакового пространства.

Разработана функциональная модель системы поддержки принятия решений, описывающая технологический процесс обработки информации в двух режимах работы (рис. 3). Системный анализ МКС как многопараметрического объекта с нелинейной динамикой [18, 19] определил выбор двухрежимной архитектуры.

В штатном режиме (период опроса 2 часа) информация последовательно проходит четыре стадии обработки. Сенсорная подсистема формирует вектор измерений $X_{raw} \in R^5$. Алгоритм интеллектуальной поддержки принятия решений выполняет преобразование признакового пространства, классификацию состояния и формирование рекомендации. Оператор принимает окончательное решение на основе рекомендации и собственного опыта. Результаты каждого цикла обработки буферизуются в памяти планшета.

В режиме адаптации (при плановом техническом обслуживании, раз в 3–6 месяцев) накопленные данные телеметрии выгружаются с планшета и сопоставляются с журналом фактических доливов из учетной системы. На основе этих данных выполняется переобучение модели с последующей валидацией по двойному критерию. При выполнении критериев качества обновленная модель загружается на контроллер, замыкая обратный контур.




Рис. 3. Функциональная модель системы поддержки принятия решений
Fig. 3. Functional model of decision support system

Разработано авторами

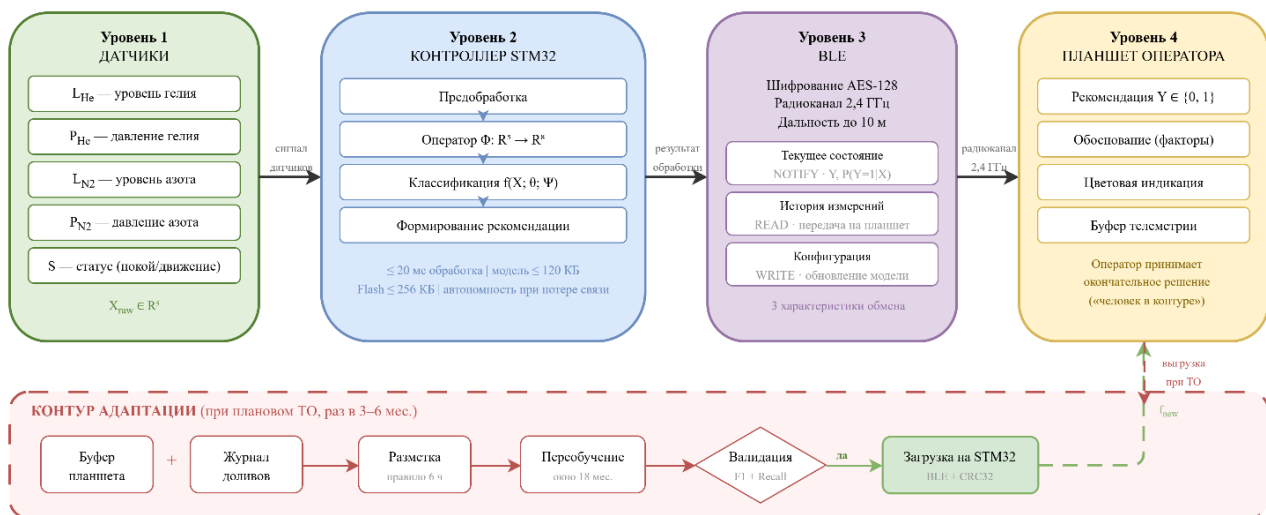


Рис. 4. Четырехуровневая архитектура развертывания
Fig. 4. Four-level deployment architecture

Разработано авторами

Функциональная модель реализована в четырехуровневой архитектуре развертывания (рис. 4). Первый уровень – датчики арматурного узла контейнера. Второй уровень – бортовой контроллер STM32, на котором выполняются предобработка, преобразование, классификация и формирование рекомендации. Третий уровень – канал связи BLE с шифрованием AES-128 [20]. Четвертый уровень – планшет оператора с интерфейсом рекомендаций и буфером накопления данных.

Алгоритм адаптации модели на эксплуатационных данных описывает процесс обновления

модели, привязанный к плановому техническому обслуживанию (рис. 5). Данные телеметрии выгружаются на рабочую станцию, сопоставляются с журналом фактических доливов. Разметка выполняется автоматически по правилу временного горизонта – если долив зафиксирован в течение 6 часов после наблюдения, ему присваивается метка $Y = 1$. Обучающая выборка формируется по скользящему окну 18 месяцев. После переобучения выполняется валидация по двойному критерию. При выполнении обоих критериев обновленная модель загружается на контроллер через BLE с верификацией целостности (CRC32).




Рис. 5. Алгоритм адаптации модели на эксплуатационных данных
Fig. 5. Model adaptation algorithm on operational data

Разработано авторами

Для подтверждения выполнимости ограничений вектора Ψ выполнен расчет ресурсов. Объем памяти модели:

$$V = N_{tree} \cdot N_{node} \cdot B_{node}, \quad (12)$$

где $N_{tree} = 200$, $N_{node} \approx 300$, $B_{node} = 13$ байт. Подстановка дает $V = 78$ КБ, с учетом служебных данных 80–120 КБ при ограничении 256 КБ. Время обработки:

$$T = N_{tree} \cdot D_{avg} \cdot t_{node} + T_{head}, \quad (13)$$

где $D_{avg} \approx 7$ — средняя глубина обхода, $t_{node} \approx 50$ нс. Полный цикл не более 20 мс при ограничении 50 мс.

Разработана архитектура программного комплекса, реализованного в двух программных

продуктах (рис. 6). Программа сбора и обработки данных обеспечивает прием телеметрии, авторизацию пользователей и хранение данных. Программа интеллектуальной поддержки принятия решений реализует полный конвейер обработки информации.

Интерфейс оператора реализован в виде мобильного приложения на планшете (рис. 7). Главный экран отображает текущую рекомендацию с цветовой индикацией, степень уверенности модели и ведущие факторы решения. Экран деталей рейса содержит графики изменения параметров по времени. Экран истории позволяет просматривать журнал рекомендаций и фактических решений оператора.

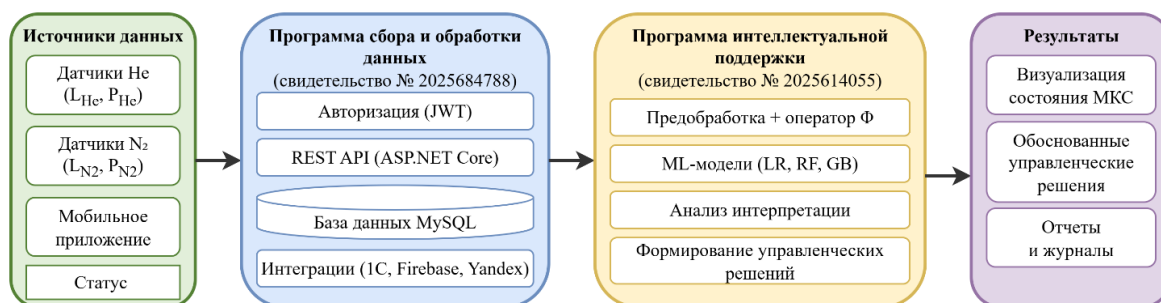


Рис. 6. Архитектура программного комплекса интеллектуальной поддержки управления МКС
Fig. 6. Architecture of intelligent MCS management software complex

Разработано авторами

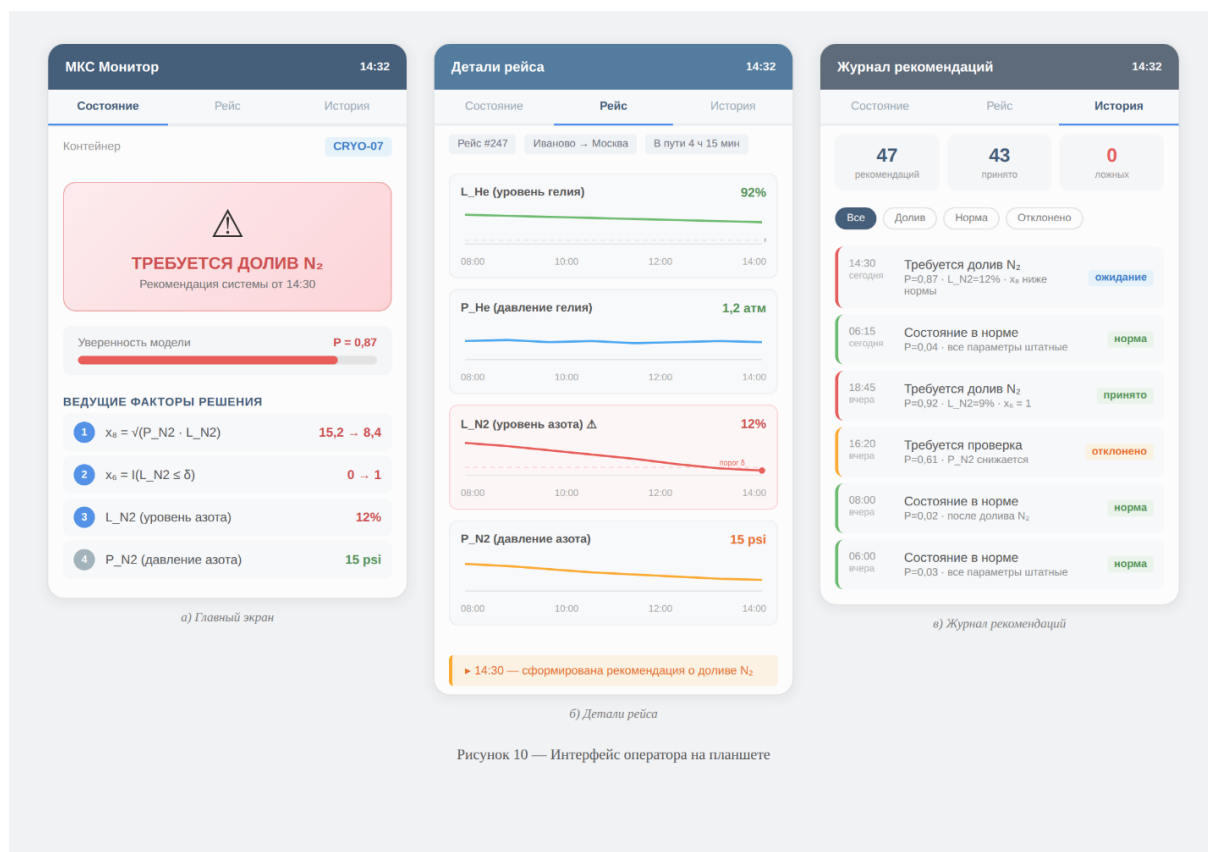


Рис. 7. Интерфейс оператора на планшете
Fig. 7. Operator interface on tablet

Разработано авторами

Сравнение с ручным контролем проводилось на эксплуатационных данных парка контейнеров (табл. 3).

Проведена оценка работоспособности механизма адаптации модели за 18 месяцев промышленной эксплуатации (табл. 4).

Во всех четырех циклах оба критерия ($F1 \geq F1_{old} - 0,05$ и $Recall \geq 0,95$) были выполнены. F1 не опускалась ниже 0,875. Снижение F1

Таблица 3

Сравнение ручного контроля и интеллектуальной системы поддержки
Table 3. Comparison of manual control and intelligent support system

Показатель	Ручной контроль	Интеллектуальная система	Изменение
F1-мера	0,46	0,89	+93%
Recall	0,58	0,86	+48%
Precision	0,38	0,92	+142%
Время реакции, мин	204	2,3	-99%
Ложные срабатывания, %	4,9	0,6	-88%

Разработано авторами

Таблица 4

Результаты циклов адаптации
Table 4. Adaptation cycle results

Ци кл	Объем выборки	F1 (f_new)	Recall (f_new)	Решение
1	890	0,912	0,961	замена
2	1050	0,898	0,952	замена
3	1180	0,905	0,968	замена
4	1320	0,880	0,955	замена

Разработано авторами

в четвертом цикле с 0,912 до 0,880 объясняется включением летних рейсов с нетипичным температурным профилем, при этом Recall сохранен на уровне 0,955, ни одно критическое событие не пропущено за весь период эксплуатации. Поэтапное внедрение обеспечило снижение ложных тревог на 63%, сокращение времени реакции оператора в 5 раз и экономический эффект в размере 7–10% снижения эксплуатационных затрат в годовом исчислении.

ЗАКЛЮЧЕНИЕ

В статье получены следующие научные результаты. Введен оператор преобразования $\Phi: R^5 \rightarrow R^8$, конструирующий три производных признака на основе термодинамических зависимо-

стей между параметрами гелиевого и азотного контуров. Производные признаки формируют 78% суммарного вклада в решения модели, что привело к росту F1-меры с 0,653 (логистическая регрессия на исходном пространстве) до 0,925 (случайный лес на расширенном пространстве). Построена вычислительно эффективная процедура формирования рекомендаций оператору, работающая в рамках 20 мс и 120 КБ на контроллере STM32 и обеспечившая сокращение времени от поступления данных до обоснованного решения с 204 до 2,3 минуты. Предложена супервизорная архитектура с обратной связью, в которой циклическое переобучение по скользящему окну 18 месяцев при двойном контроле (по F1 и полноте) не допустило ни одного пропуска критического события за весь период промышленных испытаний [21].

Полученные результаты могут быть пере-

несены на иные технические объекты со схожей архитектурой информационного потока, в том числе на системы хранения и транспортировки сжиженного природного газа, водородные топливные системы и промышленные криогенные установки в фармацевтическом и пищевом производстве. Перспективным направлением является создание облачной платформы групповой адаптации, позволяющей аккумулировать эксплуатационные данные парка контейнеров и обучать единую мета-модель с последующим её распространением на бортовые контроллеры.

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. Горев С.В., Астраханцева И.А., Котенев Т.Е., Астраханцев Р.Г. Оптимизация эксплуатации многослойных криогенных систем с применением методов машинного обучения и стандартизированных протоколов внедрения. *Современные наукоемкие технологии. Региональное приложение*. 2025. № 2(82). С. 59–70.
2. Горев С.В., Астраханцева И.А., Котенев Т.Е. 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.
3. Горев С.В., Астраханцева И.А., Котенев Т.Е. и др. Метод градиентного бустинга при прогнозировании управленческих решений в многослойной криогенной системе. *Современные наукоемкие технологии. Региональное приложение*. 2024. № 2(78). С. 50–58.
4. Архаров А.М., Архаров И.А., Марфенина И.В. Криогенные системы. Основы теории и расчета. М.: Машиностроение, 1996. 576 с.
5. Беляков В.П. Криогенная техника и технология. М.: Энергоиздат, 1982. 272 с.
6. Van Sciver S.W. Helium Cryogenics. 2nd ed. New York: Springer, 2012. 470 p.
7. Зарубин В.С., Кувыркин А.П. Математическое моделирование в технике. М.: МГТУ им. Н. Э. Баумана, 2010. 495 с.
8. Tilaro F., Bradu B., Gonzalez-Berges M. Machine learning techniques for the CERN Large Hadron Collider cryogenic system. *IOP Conference Series: Materials Science and Engineering*. 2020. Vol. 755. P. 012061.
9. Kim M., Seong H., Kim D. Deep learning-based prognostics for cryogenic system. *Cryogenics*. 2022. Vol. 125. P. 103503.
10. Saha S.K., Prasad G. Predictive maintenance of cryogenic pumps using machine learning. *International Journal of Refrigeration*. 2021. Vol. 131. P. 218–228.
11. Shannon C.E. A Mathematical Theory of Communication. *The Bell System Technical Journal*. 1948. Vol. 27. P. 379–423.
12. Советов Б.Я., Яковлев С.А. Моделирование систем. 7-е изд. М.: Юрайт, 2012. 343 с.
13. Новиков Д.А. Теория управления организационными системами. 3-е изд. М.: Физматлит, 2012. 604 с.

REFERENCES

1. Gorev S.V., Astrakhantseva I.A., Kotenev T.E., Astrakhantsev R.G. Optimization of multilayer cryogenic system operation using machine learning methods and standardized implementation protocols. *Modern high technology. Regional application*. 2025. N 2(82). P. 59–70.
2. Gorev S.V., Astrakhantseva I.A., Kotenev T.E. et al. Artificial intelligence methods in multilayer cryogenic system control with vacuum insulation and nitrogen shield. *Modern high technology. Regional application*. 2024. N 1(77). P. 50–59.
3. Gorev S.V., Astrakhantseva I.A., Kotenev T.E. et al. Gradient boosting method for predicting management decisions in multilayer cryogenic system. *Modern high technology. Regional application*. 2024. N 2(78). P. 50–58.
4. Arkharov A.M., Arkharov I.A., Marfenina I.V. Cryogenic systems. Fundamentals of theory and calculation. Moscow: Mashinostroenie, 1996. 576 p.
5. Belyakov V.P. Cryogenic engineering and technology. Moscow: Energoizdat, 1982. 272 p.
6. Van Sciver S.W. Helium Cryogenics. 2nd ed. New York: Springer, 2012. 470 p.
7. Zarubin V.S., Kuvyrkin A.P. Mathematical modeling in engineering. Moscow: MG TU im. N. E. Bauman, 2010. 495 p.
8. Tilaro F., Bradu B., Gonzalez-Berges M. Machine learning techniques for the CERN Large Hadron Collider cryogenic system. *IOP Conference Series: Materials Science and Engineering*. 2020. Vol. 755. P. 012061.
9. Kim M., Seong H., Kim D. Deep learning-based prognostics for cryogenic system. *Cryogenics*. 2022. Vol. 125. P. 103503.
10. Saha S.K., Prasad G. Predictive maintenance of cryogenic pumps using machine learning. *International Journal of Refrigeration*. 2021. Vol. 131. P. 218–228.
11. Shannon C.E. A Mathematical Theory of Communication. *The Bell System Technical Journal*. 1948. Vol. 27. P. 379–423.
12. Sovetov B.Ya., Yakovlev S.A. Systems modeling. 7th ed. Moscow: Yurait, 2012. 343 p.
13. Novikov D.A. Theory of organizational systems management. 3rd ed. Moscow: Fizmatlit, 2012. 604 p.
14. Raissi M., Perdikaris P., Karniadakis G.E. Physics-informed neural networks: a deep learning framework for

14. **Raissi M., Perdikaris P., Karniadakis G.E.** Physics-informed neural networks: a deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*. 2019. Vol. 378. P. 686–707.
15. **Lundberg S.M., Lee S.-I.** A Unified Approach to Interpreting Model Predictions. *Advances in Neural Information Processing Systems 30 (NIPS 2017)*. 2017. P. 4765–4774.
16. **Warden P., Situnayake D.** TinyML: Machine Learning with TensorFlow Lite on Arduino and Ultra-Low-Power Microcontrollers. Sebastopol: O'Reilly Media, 2020. 504 p.
17. **Горев С.В., Астраханцева И.А., Котенев Т.Е., Астраханцев Р.Г., Грименицкий П.Н.** 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.
18. **Горев С.В., Астраханцева И.А., Астраханцев Р.Г.** Фрактальный анализ в оценке эффективности и надежности сложных технических систем. *Современные наукоемкие технологии. Региональное приложение*. 2023. № 4(76). С. 60–68.
19. **Горев С.В., Астраханцева И.А., Астраханцев Р.Г.** Системный подход к анализу фрактальной природы сложных технических систем. *Известия высших учебных заведений. Серия «Экономика, финансы и управление производством» [Ивэкофин]*. 2023. № 3(57). С. 89–97.
20. **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. Vol. 20. P. 469–476.
21. **Горев С.В.** Методология интеллектуальной поддержки принятия решений при эксплуатации многослойных криогенных систем. *Известия высших учебных заведений. Серия «Экономика, финансы и управление производством» [Ивэкофин]*. 2026. № 1(67). С. 71–84.
- solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*. 2019. Vol. 378. P. 686–707.
15. **Lundberg S.M., Lee S.-I.** A Unified Approach to Interpreting Model Predictions. *Advances in Neural Information Processing Systems 30*, 2017. P. 4765–4774.
16. **Warden P., Situnayake D.** TinyML: Machine Learning with TensorFlow Lite on Arduino and Ultra-Low-Power Microcontrollers. Sebastopol, O'Reilly Media, 2020. 504 p.
17. **Gorev S.V., Astrakhantseva I.A., Kotenev T.E., Astrakhantsev R.G., Grimenitsky P.N.** Integration of linear regression and random forest methods into intelligent support systems for cryogenic transport systems. *Ivecofin*. 2024. N 3(61). P. 81–90.
18. **Gorev S.V., Astrakhantseva I.A., Astrakhantsev R.G.** Fractal analysis in assessing the efficiency and reliability of complex technical systems. *Modern high technology. Regional application*. 2023. N 4(76). P. 60–68.
19. **Gorev S.V., Astrakhantseva I.A., Astrakhantsev R.G.** A systemic approach to the analysis of the fractal nature of complex technical systems. *Ivecofin*. 2023. N 3(57). P. 89–97.
20. **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. Vol. 20. P. 469–476.
21. **Gorev S.V.** Methodology of intelligent decision support in multilayer cryogenic system operation. *Ivecofin*. 2026. N 1(67). P. 71–84.

Поступила в редакцию 10.12.2026
Принята к опубликованию 18.05.2026

Received 10.12.2026
Accepted 18.05.2026