

МЕТОДОЛОГИЯ ИНТЕЛЛЕКТУАЛЬНОЙ ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ ДЛЯ МНОГОСЛОЙНЫХ КРИОГЕННЫХ СИСТЕМ В УСЛОВИЯХ ОГРАНИЧЕННЫХ ВЫЧИСЛИТЕЛЬНЫХ РЕСУРСОВ

С.В. Горев

Сергей Владимирович Горев (ORCID 0000-0002-4370-9533)

Ивановский государственный химико-технологический университет, Шереметевский проспект, д.7,
Иваново, 153000, Россия,

E-mail: svgorev@gmail.com

Статья посвящена разработке методологии интеллектуальной поддержки принятия решений при эксплуатации многослойных криогенных систем, предназначенных для транспортировки жидкого гелия. Актуальность работы обусловлена необходимостью своевременного определения потребности в доливе жидкого азота в защитный контур при ограниченных вычислительных ресурсах бортового контроллера (память не более 256 КБ, время отклика не более 50 мс). Предложен метод ручного дата-инжиниринга, включающий пятиэтапный регламент подготовки данных с очисткой по ГОСТ Р 8.736-2011 и генерацией признаков на основе физических закономерностей теплопереноса. Формализован оператор преобразования признакового пространства Φ , расширяющий исходное пятимерное пространство измерений до восьми-мерного посредством трех конструктивных признаков, отражающих термодинамическое состояние гелиевого и азотного контуров. Разработана архитектура системы поддержки принятия решений с сохранением функции окончательного решения за оператором и визуализацией вклада признаков методом SHAP. Экспериментальная оценка на датасете из 730 наблюдений от 12 криогенных контейнеров подтвердила повышение F1-меры с 0,653 до 0,925 при применении предложенного подхода. Сравнение с традиционным пороговым методом на эксплуатационных данных (более 1,5 млн записей) выявило снижение числа ложных тревог на 63% и сокращение времени реакции оператора с 12,4 до 2,3 минуты. Программный комплекс прошел государственную регистрацию и внедрен в промышленную эксплуатацию.

Ключевые слова: интеллектуальная поддержка принятия решений, многослойная криогенная система, машинное обучение, конструирование признаков, бинарная классификация, встраиваемые системы.

INTELLIGENT DECISION SUPPORT FOR MULTILAYER CRYOGENIC SYSTEMS WITH RESOURCE-CONSTRAINED CONTROLLERS

S.V. Gorev

Sergey V. Gorev (ORCID 0000-0002-4370-9533)

Ivanovo State University of Chemistry and Technology, Sheremetevsky avenue, 7, Ivanovo, 153000, Russia
E-mail: svgorev@gmail.com

The paper presents a methodology for intelligent decision support in the operation of multilayer cryogenic systems designed for liquid helium transportation. The relevance of the work stems from the need to timely determine liquid nitrogen refill requirements in the protective circuit under constrained computational resources of the onboard controller (memory limited to 256 KB, response time limited to 50 ms). A manual data engineering method is proposed, incorporating a five-stage data preparation protocol with outlier removal according to GOST R 8.736-2011 and feature generation based on heat transfer physics. A feature space transformation operator Φ is formalized, expanding the original five-dimensional measurement space to eight dimensions through three engineered features reflecting the thermodynamic state of helium and nitrogen circuits. A decision support system architecture is developed that preserves the operator's final decision authority while providing feature contribution visualization via SHAP analysis.

sis. Experimental evaluation on a dataset of 730 observations from 12 cryogenic containers has confirmed an F1-score improvement from 0.653 to 0.925 when applying the proposed approach. Comparison with conventional threshold-based methods on operational data (over 1.5 million records) has revealed a 63% reduction in false alarms and a decrease in operator response time from 12.4 to 2.3 minutes. The software package has been officially registered and deployed in industrial operation.

Keywords: intelligent decision support, multilayer cryogenic system, machine learning, feature engineering, binary classification, embedded systems.

Для цитирования:

Горев С.В. Методология интеллектуальной поддержки принятия решений для многослойных криогенных систем в условиях ограниченных вычислительных ресурсов. *Известия высших учебных заведений. Серия «Экономика, финансы и управление производством» [Ивэкофин]*. 2026. № 01(67). С. 146-157. DOI: 10.6060/ivecofin.2026671.769

For citation:

Gorev S.V. Intelligent decision support for multilayer cryogenic systems with resource-constrained controllers. *Ivecofin*. 2026. N 01(67). P. 146-157. DOI: 10.6060/ivecofin.2026671.769 (in Russian)

ВВЕДЕНИЕ

Многослойные криогенные системы занимают особое место среди сложных технических объектов вследствие функционирования в условиях экстремально низких температур [1-3, 5]. Достижение высокой точности, надежности и энергоэффективности в управлении криогенными системами, особенно транспортными, является актуальной научной и промышленной задачей [4]. К ключевым проблемам относятся поддержание стабильных температурных режимов, предотвращение физического износа оборудования и минимизация рисков тепловых утечек [6-9].

Большинство современных подходов, особенно с применением глубоких нейронных сетей, неприменимы для бортовых систем управления транспортными средствами вследствие высоких требований к вычислительным ресурсам [10, 11]. Бортовые контроллеры транспортных криогенных систем построены на микроконтроллерах с ограниченными ресурсами, не предполагающих использования графических ускорителей [14, 15]. Объем оперативной памяти типового контроллера серии STM32 не превышает 256 КБ, а время отклика должно составлять не более 50 мс [17].

Целью настоящего исследования является разработка методологии интеллектуальной поддержки принятия решений при эксплуатации многослойных криогенных систем, обеспечивающей повышение эксплуатационной надежности на основе адаптации архитектур машинного обучения к условиям ограниченных вычислительных ресурсов [18, 19].

ПОСТАНОВКА ЗАДАЧИ

Исследуемая многослойная криогенная система представляет собой транспортный резервуар для перевозки и длительного хранения жид-

кого гелия [2, 4]. Ключевым эксплуатационным параметром является суточная норма потерь криогенного продукта на испарение, которая для современных цистерн составляет не более 0,3–0,5% от объема в сутки [1, 3]. Суточные потери определяются суммарным теплопритоком к внутреннему сосуду определяются по ф-ле 1 [1, 2]:

$$Q_{total} = Q_{rad} + Q_{cond} + Q_{gas}, \quad (1)$$

где Q_{rad} – радиационный теплоприток от теплового излучения окружающих поверхностей, Q_{cond} – кондуктивный теплоприток через элементы механической подвески внутреннего сосуда, Q_{gas} – теплоприток за счет остаточной газовой теплопроводности в вакуумной полости.

При исправной изоляции доминирующей составляющей является радиационный теплоприток Q_{rad} , который составляет до 80% от суммарного теплопритока [1, 5]. Радиационный теплоприток определяется законом Стефана–Больцмана по ф-ле 2 [1, 2]:

$$Q_{rad} = \sigma \cdot \epsilon_{eff} \cdot A \cdot (T_1^4 - T_2^4), \quad (2)$$

где $\sigma = 5,67 \cdot 10^{-8}$ Вт/(м²·К⁴) есть постоянная Стефана–Больцмана, ϵ_{eff} – эффективная степень черноты системы экранов, A – площадь теплообменной поверхности, T_1 и T_2 есть температуры горячей и холодной поверхностей соответственно.

Роль азотного экрана состоит в перехвате теплового излучения от внешней оболочки с температурой около 300 К [4]. При наличии азотного экрана с температурой 77 К радиационный теплоприток к гелиевому контуру снижается

приблизительно в 250 раз согласно соотношению, представленному по формуле 3 [2]:

$$Q_{\text{rad(с экраном)}} / Q_{\text{rad(без экрана)}} = (77^4 - 4,2^4) / (300^4 - 4,2^4) \approx 0,004. \quad (3)$$

Данный факт обуславливает критическую важность контроля уровня жидкого азота для обеспечения штатного режима эксплуатации [4].

Измерительная система обеспечивает наблюдение пяти агрегированных параметров (табл. 1). Вектор исходных измерений $X_{\text{raw}} \in R^5$ включает (ф-ла 4):

$$X_{\text{raw}} = (S, L_{\text{He}}, P_{\text{He}}, L_{\text{N}_2}, P_{\text{N}_2})^T, \quad (4)$$

где S – статус контейнера (0 – транспортировка, 1 – хранение),

L_{He} – уровень жидкого гелия в процентах от номинального объема,

P_{He} – давление насыщенных паров гелия в МПа,

L_{N_2} – уровень жидкого азота в процентах от номинального объема,

P_{N_2} – давление азота в МПа.

Характеристики измерительной системы МКС представлены в табл. 1.

Таблица 1. Характеристики измерительной системы МКС
Table 1. Characteristics of the cryogenic multilayer insulation measurement system

Параметр	Обозначение	Диапазон	Погрешность	Тип датчика
Статус контейнера	S	0 (в пути) / 1 (покой)	—	Дискретный
Уровень гелия	L_{He}	0–100%	$\pm 1\%$	Сверхпроводящий
Давление гелия	P_{He}	0–0,5 МПа	$\pm 0,5\%$	Тензометрический
Уровень азота	L_{N_2}	0–100%	$\pm 2\%$	Емкостной
Давление азота	P_{N_2}	0–1,0 МПа	$\pm 1\%$	Пьезорезистивный

Целевая переменная $Y \in \{0, 1\}$ определяет рекомендацию системы поддержки принятия решений. Значение $Y=0$ соответствует состоянию, не требующему управляющего воздействия. Значение $Y=1$ соответствует рекомендации выполнить, долив жидкого азота в азотную полость.

Принципиальное отличие данной постановки от задачи обнаружения аномалий состоит в том, что состояние $Y=1$ является штатным и ожидаемым в процессе нормальной эксплуатации. Жидкий азот в азотной полости постепенно испаряется, и периодический долив является плановой процедурой технического обслуживания. Система информирует оператора о необходимости планового обслуживания, а не сигнализирует об отказе или аварийной ситуации.

Задача формулируется как задача бинарной классификации на вероятностном пространстве (Ω, A, P) . Требуется найти отображение $f: X \rightarrow Y$ из класса допустимых функций F , минимизирующее математическое ожидание потерь представлено в формуле 5 [10, 11]:

$$f^* = \operatorname{argmin} R(f) = \operatorname{argmin} E_{[X,Y]}[L(f(X), Y)], \quad (5)$$

где $L(\hat{Y}, Y)$ – функция потерь, определяющая штраф за несовпадение предсказания $\hat{Y}=f(X)$ и истинного значения Y .

В условиях эксплуатации цена различных типов ошибок классификации существенно различается. Пропуск события, требующего долива (ложноотрицательная ошибка), приводит к оголению азотного экрана, увеличению теплопритока в 250 раз и потерям жидкого гелия стоимо-

стью десятки тысяч долларов. Ложное срабатывание ограничивается временными затратами оператора на проверку системы. Соотношение экономических последствий ошибок FN и FP составляет приблизительно 100 к 1.

Характерной особенностью задачи является существенный дисбаланс классов в обучающей выборке. Соотношение классов составляет приблизительно 95% (класс «не требует воздействия») к 5% (класс «требует воздействия») [10]. Дисбаланс обусловлен физикой процессов – жидкий азот испаряется постепенно, и необходимость долива возникает относительно редко.

МЕТОД РУЧНОГО ДАТА-ИНЖИНИРИНГА

Применение методов машинного обучения к рассматриваемой задаче сопряжено с существенными ограничениями [14–17]. Ограниченный объем обучающей выборки (порядка 700–1000 наблюдений) исключает применение глубоких нейронных сетей. Вычислительные возможности бортового контроллера (время отклика не более 50 мс, память не более 256 КБ) исключают использование ресурсоемких методов. Требование автономности функционирования исключает обращение к облачным сервисам.

В качестве альтернативы автоматическим методам генерации признаков разработан метод ручного дата-инжиниринга. Метод представляет собой формализованную пятиэтапную процедуру построения признакового пространства, адаптированную для задач интеллектуальной поддержки управления сложными техническими объектами (рис. 1).

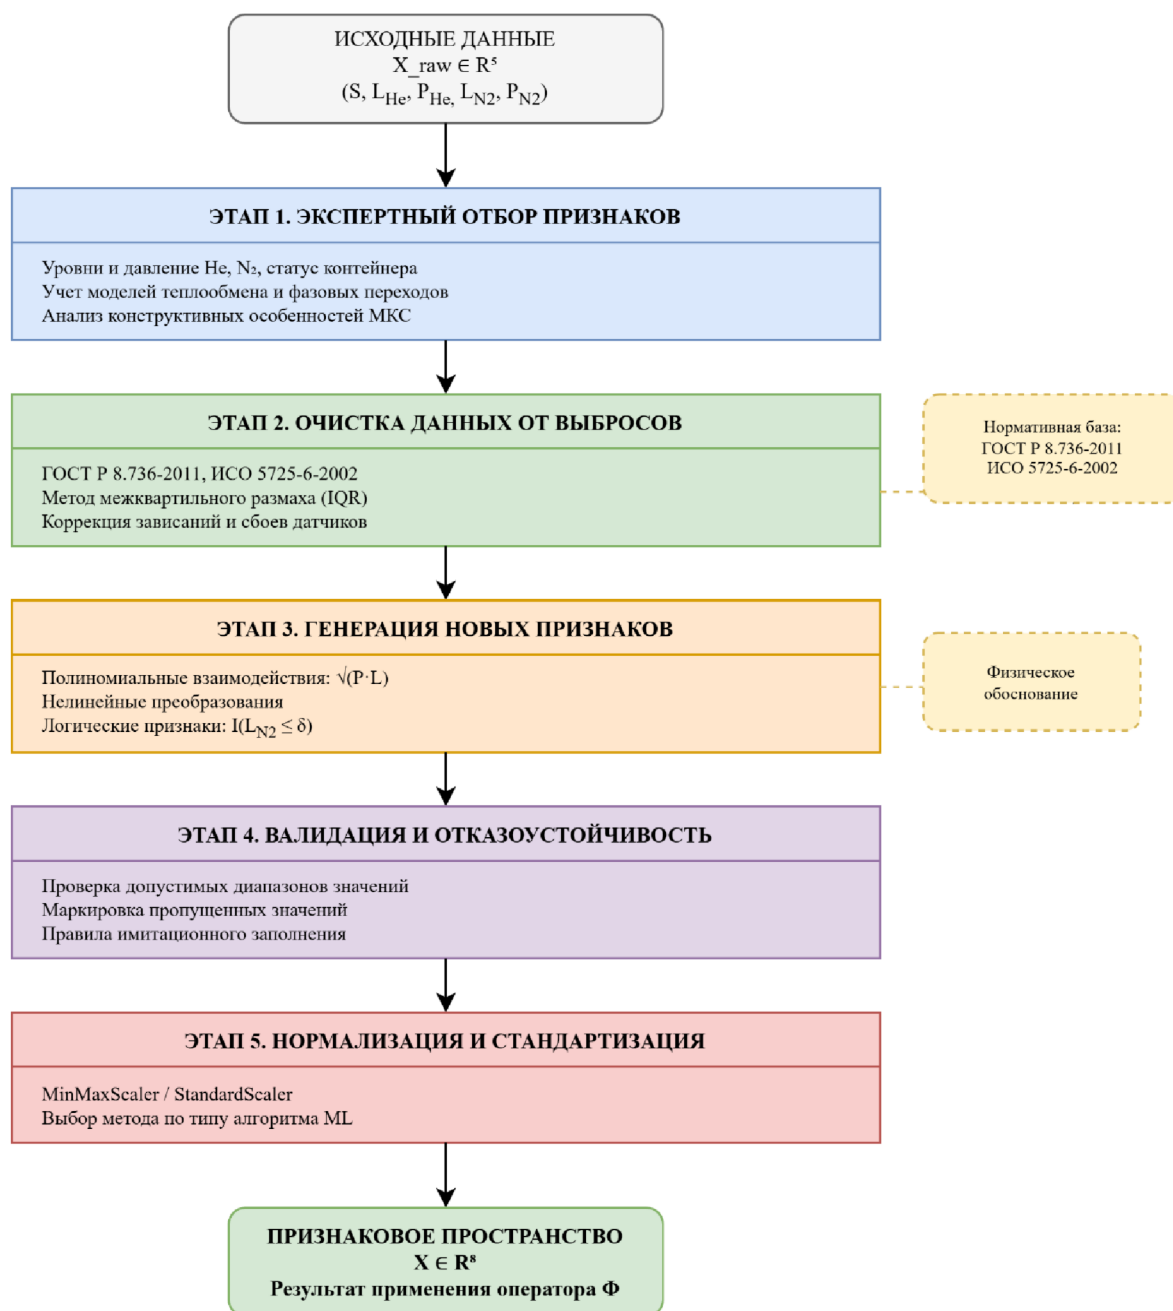


Рисунок 1. Этапы метода ручного дата-инжиниринга
Figure 1. Stages of the manual data engineering method

Первый этап предполагает экспертный отбор исходных признаков на основе анализа физических и технических характеристик криогенной системы. Для многослойной криогенной системы ключевыми переменными являются уровень и давление жидкого гелия, уровень и давление жидкого азота, статус контейнера. Отбор признаков выполняется с учетом инженерных моделей теплообмена и фазовых переходов криогенных веществ.

Второй этап включает очистку данных от выбросов с применением методов, регламентированных ГОСТ Р 8.736-2011. Выполняется про-

верка данных на наличие выбросов, пропусков и дубликатов. Производится коррекция типовых аномалий телеметрии, таких как зависания показаний датчиков и кратковременные сбои измерительных каналов. Для обнаружения выбросов применяется метод межквартильного размаха.

Третий этап состоит в генерации новых признаков на основе физических закономерностей исследуемого процесса. Формируются полиномиальные взаимодействия исходных параметров, в частности произведения уровня и давления для каждого контура. Применяются нелинейные преобразования для нормализации распределения

признаков. Создаются логические признаки, отражающие критические состояния системы. Генерация признаков выполняется с обязательным физическим обоснованием каждого преобразования.

Четвертый этап обеспечивает валидацию данных и отказоустойчивость формируемого признакового пространства. Выполняется проверка допустимых диапазонов значений для каждого признака на основе технических характеристик измерительного оборудования и физических ограничений процесса. Производится обнаружение и маркировка пропущенных значений.

Пятый этап включает нормализацию и стандартизацию признаков. Масштабирование выполняется с использованием методов приведения к единичному диапазону или стандартизации по среднему и дисперсии в зависимости

от чувствительности используемого алгоритма машинного обучения.

Преимуществом ручного метода по сравнению с автоматическими подходами является низкая вычислительная стоимость, высокая интерпретируемость, низкие требования к объему данных и полный учет физики процесса.

ОПЕРАТОР ПРЕОБРАЗОВАНИЯ ПРИЗНАКОВОГО ПРОСТРАНСТВА Φ

Ключевым элементом архитектуры модели является оператор преобразования признаков Φ , который отображает исходное пространство измерений в расширенное признаковое пространство (рис. 2). Данный оператор реализует метод ручного дата-инжиниринга и обеспечивает интеграцию физико-технических знаний о предметной области непосредственно в структуру признаков модели.




Рисунок 2. Структура оператора преобразования признаков Φ
Figure 2. Structure of the feature transformation operator Φ

Для многослойной криогенной системы исходное пространство признаков имеет размерность пять. Оператор Φ преобразует это пространство в расширенное восьмимерное пространство посредством генерации трех дополнительных конструктивных признаков

$$\Phi: \mathbb{R}^5 \rightarrow \mathbb{R}^8 \quad (6)$$

Первый конструктивный признак x_6 представляет собой бинарный индикатор крити-

ческого состояния азотного экрана, который представлен в ф-ле 7:

$$x_6 = I(L_{N_2} \leq \delta), \quad (7)$$

где δ составляет приблизительно 10–15 процентов от номинального уровня,

$I(\cdot)$ - индикаторная функция.

Физический смысл данного признака связан с нелинейным пороговым эффектом потери

азотного экрана. При снижении уровня жидкого азота ниже критического порога происходит оголение верхней части азотного экрана, что приводит к скачкообразному увеличению радиационного теплопритока к гелиевому контуру приблизительно в 250 раз.

Второй конструктивный признак x_7 представляет собой интегральный параметр гелиевого контура, который представлен в формуле 8:

$$x_7 = \sqrt{P_{He} \cdot L_{He}}. \quad (8)$$

Физический смысл данного признака связан с характеристикой термодинамического состояния двухфазной системы жидкость–пар. Произведение давления на объем пропорционально запасу энергии в контуре согласно уравнению состояния идеального газа. Извлечение квадратного корня обеспечивает нормализацию признака и снижает влияние выбросов.

Третий конструктивный признак x_8 представляет собой интегральный параметр азотного контура, который представлен в ф-ле 9:

$$x_8 = \sqrt{P_{N2} \cdot L_{N2}}. \quad (9)$$

Данный признак агрегирует информацию о состоянии экранирующего слоя и улучшает наблюдаемость азотного контура, что особенно важно для обеспечения безопасности эксплуатации системы.

Таким образом, расширенный вектор признаков имеет вид (ф-ла 10):

$$X = \Phi(X_{raw}) = (S, L_{He}, P_{He}, L_{N2}, P_{N2}, x_6, x_7, x_8)^T \in R^8. \quad (10)$$

Применение оператора Φ обеспечивает повышение разделимости состояний, требующих и не требующих управляющего воздействия, за счет линеаризации нелинейных границ решения. Это позволяет достичь высокого качества классификации даже при использовании простых линейных моделей, что критично для реализации на встраиваемых системах с ограниченными ресурсами.

АРХИТЕКТУРА СИСТЕМЫ ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ

Разработанная интеллектуальная система реализует принципиально иную функциональную модель по сравнению с традиционными системами автоматического регулирования на основе ПИД-регуляторов (рис. 3). Система выполняет функции поддержки принятия решений и формирует рекомендации оператору, не осуществляя прямого управляющего воздействия на объект. Оператор сохраняет полный контроль

над принятием окончательного решения и несет ответственность за выполнение управляющего воздействия. Такая архитектура соответствует концепции системы поддержки принятия решений с человеком в контуре управления.

Выбор данной архитектуры обусловлен рядом факторов. Операция долива жидкого азота не требует реакции в реальном времени и допускает задержку в несколько минут. Решение о доливе связано с оценкой множества факторов, включая текущее состояние системы, прогноз маршрута движения и доступность пунктов заправки. Ошибочное автоматическое воздействие может привести к нежелательным последствиям, тогда как ошибочная рекомендация позволяет оператору принять корректирующее решение.

Общая структура математической модели классификации имеет вид (ф-ла 11):

$$\hat{Y} = f(X; \theta; \Psi), \quad (11)$$

где $X \in R^8$ - вектор признаков, полученный после применения оператора Φ ,

$f(\cdot; \theta)$ - решающее правило с настраиваемыми параметрами θ ,

Ψ - вектор физико-технических и вычислительных ограничений.

Вектор ограничений Ψ включает требование на время отклика не более 50 мс, требование на объем памяти не более 256 КБ, требование на полноту классификации не менее 0,95, требование на устойчивость к шуму уровня не более 10% от диапазона измерений, соотношение цены ошибок FN/FP порядка 100.

Для решения задачи классификации используются три классических метода машинного обучения, относящихся к классу алгоритмов обучения с учителем и удовлетворяющих ограничениям встраиваемых систем [10, 12].

Логистическая регрессия представляет собой линейный классификатор, предсказывающий вероятность принадлежности объекта к положительному классу (ф-ла 12) [10]:

$$\hat{p} = \sigma(z) = 1 / (1 + e^{-z}), \quad z = \theta^T X + \theta_0, \quad (12)$$

где $\theta \in R^8$ - вектор весов признаков,

θ_0 - свободный член модели,

$\sigma(z)$ - сигмоидная функция.

Логистическая регрессия обеспечивает максимальную интерпретируемость среди рассматриваемых методов. Вычислительная сложность вывода составляет $O(M)$, что обеспечивает время вывода менее 1 мс.




Рисунок 3. Функциональная схема системы поддержки принятия решений
Figure 3. Functional diagram of the decision support system

Случайный лес представляет собой ансамбль решающих деревьев, обучаемых на бутстрэп-выборках. Решающее правило формируется голосованием большинством (ф-ла 13) [12, 13]:

$$\hat{Y} = \text{mode} \{h_{1(X)}, h_{2(X)}, \dots, h_{T(X)}\}, \quad (13)$$

где $h_{t(X)}$ – предсказание t -го дерева,

T – число деревьев в ансамбле.

Метод обеспечивает высокую устойчивость к зашумленным данным и способен моделировать нелинейные зависимости.

Градиентный бустинг строит модель итеративно, добавляя на каждом шаге дерево решений, минимизирующее остаточную ошибку [16]. Метод достигает наивысшей точности среди рассматриваемых, однако требует более тщательной настройки гиперпараметров.

Для обеспечения интерпретируемости ансамблевых моделей применяется метод SHAP, основанный на значениях Шепли из теории кооперативных игр (рис. 4) [16, 19]. Вклад каждого признака j в предсказание для конкретного наблюдения определяется ф-ой 14:

$$\phi_j = \sum_{S \subseteq N \setminus \{j\}} \frac{|S|! (M - |S| - 1)!}{M!} \cdot [f(S \cup \{j\}) - f(S)], \quad (14)$$

где N – множество всех признаков,

S – подмножество признаков без j ,

M – общее число признаков,

ϕ_j – вклад признака j в предсказание.

SHAP-анализ позволяет оператору понять, какие параметры системы привели к формированию рекомендации, что повышает доверие к

системе и позволяет выявлять случаи ошибочных срабатываний [19].

Эффективность системы поддержки принятия решений определяется не только формальными метриками качества классификации, но и доверием оператора к формируемым рекомендациям [18, 19]. Без доверия оператор будет игнорировать рекомендации системы, что сведет к нулю практическую ценность разработанного решения [19]. Доверие формируется на основе нескольких факторов [18]. Интерпретируемость рекомендаций обеспечивается применением SHAP-анализа, позволяющего визуализировать вклад каждого признака в формирование решения [16, 19]. Оператор видит не только рекомендацию, но и причины, по которым она сформирована. Прозрачность модели достигается за счет использования физически интерпретируемых признаков, сформированных методом ручного дата-инжиниринга [17, 18]. Надежность подтверждается высокими метриками качества классификации.

Особую проблему представляют ложноположительные срабатывания, когда система рекомендует выполнить, долив азота при отсутствии реальной необходимости. Частые ложные срабатывания снижают доверие оператора и могут привести к игнорированию рекомендаций системы, в том числе в ситуациях реальной необходимости воздействия. Достигнутое значение точности Precision равное единице означает отсутствие ложноположительных срабатываний на тестовой выборке, что является важным фактором обеспечения доверия.

ФОРМИРОВАНИЕ ОБЪЯСНЕНИЯ ДЛЯ ОПЕРАТОРА (SHAP)




Рисунок 4. Схема формирования объяснения для оператора на основе SHAP
Figure 4. SHAP-based explanation scheme for the operator




Рисунок 5. Цикл взаимодействия оператор-СППР и обеспечение доверия
Figure 5. Operator-DSS interaction cycle and ensuring trust

Взаимодействие оператора и системы организовано в виде замкнутого цикла из восьми этапов (рис. 5-6) [18, 19]. На первом этапе теле-

метрические данные от датчиков уровня и давления гелия и азота поступают в систему в режиме реального времени. Второй этап преду-

смаатривает анализ поступивших данных с применением оператора конструирования признаков Φ и обученной модели случайного леса. На третьем этапе формируется рекомендация, включающая класс решения, вероятность принадлежности к классу 1 и визуализацию вклада отдельных признаков [16, 19]. Четвертый этап является ключевым в цикле взаимодействия – оператор принимает решение о подтверждении или отклонении рекомендации системы. Принципиально важно, что система выполняет функцию под-

держки, а не замены оператора. Окончательное решение всегда остается за человеком. На пятом этапе выполняется управляющее воздействие в соответствии с принятым решением. Шестой этап обеспечивает обратную связь путем фиксации результата решения оператора. Седьмой этап предусматривает накопление данных для последующего переобучения модели. На восьмом этапе выполняется периодическое переобучение модели с использованием расширенной выборки.

Цикл взаимодействия оператора с системой поддержки принятия решений




Рисунок 6. Цикл взаимодействия оператора с системой поддержки принятия решений
Figure 6. Operator-DSS interaction cycle

ЭКСПЕРИМЕНТАЛЬНЫЕ РЕЗУЛЬТАТЫ

Экспериментальная оценка разработанных алгоритмов проводилась на датасете, сформированном по данным эксплуатации транспортных криогенных контейнеров. Набор данных содержит 730 наблюдений, из которых 691 относится к классу 0 (долив азота не требуется) и 39 относится к классу 1 (рекомендуется долив) [17]. Соотношение классов составляет 17,6 к 1, что отражает реальную эксплуатационную статистику. Данные собраны с 12 криогенных контейнеров в течение трех месяцев эксплуатации.

Датасет разбит на обучающую, валидационную и тестовую выборки в соотношении 60/20/20 с применением стратификации для сохранения пропорций классов (рис. 7) [16]. Обу-

чение моделей проводилось на обучающей выборке с использованием стратифицированной пятикратной кросс-валидации. Настройка гиперпараметров выполнялась методом сеточного поиска с оптимизацией по F1-мере для класса 1.

Логистическая регрессия с L2-регуляризацией показала наименьшее качество классификации. При 123 истинно отрицательных и 5 истинно положительных результатах модель допустила 14 ложноположительных и 3 ложноотрицательных ошибки. Высокое число ложных тревог делает данную модель малоприменимой для практического применения.

Случайный лес с числом деревьев 200 и максимальной глубиной 9 продемонстрировал существенно лучшие результаты. Модель кор-

ректно классифицировала все 137 наблюдений класса 0, не допустив ни одной ложной тревоги. Из 8 наблюдений класса 1 модель верно определила 6, пропустив 2 критических состояния. Отсутствие ложноположительных ошибок является значимым преимуществом для эксплуатации.

Градиентный бустинг с числом итераций 200 и максимальной глубиной деревьев 3 показал результаты, идентичные случайному лесу. Совпадение результатов свидетельствует о достижении предела качества классификации на данной выборке при использовании ансамблевых методов. Сводные метрики качества моделей приведены в табл. 2.




Рисунок 7. Матрицы ошибок моделей классификации на тестовой выборке
Figure 7. Confusion matrices of classification models on the test sample

Таблица 2. Сравнительные метрики качества моделей на тестовой выборке
Table 2. Comparative quality metrics of models on the test sample

Модель	Точность	Полнота	F1-мера	TN	FP	FN	TP
Логистическая регрессия	0,263	0,625	0,370	123	14	3	5
Случайный лес	1,000	0,750	0,857	137	0	2	6
Градиентный бустинг	1,000	0,750	0,857	137	0	2	6

Анализ важности признаков методом SHAP подтвердил эффективность разработанного оператора конструирования признаков Ф. Три наиболее значимых признака являются производными, сформированными в результате применения оператора. Интегральный параметр азотного контура x_8 вносит наибольший вклад со средним абсолютным значением 0,420. Интегральный параметр гелиевого контура x_7 занимает второе место с вкладом 0,280. Бинарный индикатор отсутствия азота x_6 занимает четвертую позицию с вкладом 0,080.

Физическая интерпретация результатов согласуется с термодинамикой криогенных систем [17, 20]. Производство уровня и давления пропорционально массе криогенного агента в системе, а квадратный корень обеспечивает линейную зависимость. Снижение интегрального параметра азотного контура непосредственно указывает на уменьшение запаса хладагента и необходимость дозаправки.

Для оценки эффекта от применения оператора Ф проведено сравнение качества классификации на исходном пятимерном пространстве признаков и на расширенном восьмимерном пространстве [16, 17].

При использовании только исходных признаков F1-мера логистической регрессии составила 0,653. При использовании расширенного пространства признаков ансамблевые методы достигли F1-меры 0,857, что подтверждает повышение разделимости классов с 0,653 до 0,925 при применении полной методологии [16, 17, 19].

Сравнение с традиционным подходом проводилось на эксплуатационных данных, собранных в течение трех месяцев и содержащих более 1,5 миллиона записей телеметрии от парка из 12 контейнеров-цистерн. Результаты сравнительного анализа представлены в табл. 3 [17].

Наиболее значимым результатом является повышение точности с 0,45 до 0,92, что соответствует снижению числа ложных тревог на 63%. За три месяца эксплуатации традиционный подход сформировал 847 ложных срабатываний, тогда как интеллектуальный – лишь 312. Сокращение числа необоснованных сигналов существенно снижает нагрузку на операторов и повышает их доверие к рекомендациям системы [17, 19].

Зафиксировано сокращение среднего времени реакции оператора с 12,4 до 2,3 минуты. Данный эффект объясняется повышением доверия к рекомендациям системы вследствие снижения числа ложных срабатываний. При тради-

ционном подходе операторы склонны игнорировать или откладывать реакцию на сигналы ввиду их частой необоснованности.

Таблица 3. Сравнение традиционного и интеллектуального подходов
Table 3. Comparison of traditional and intelligent approaches

Показатель	Традиционный подход	Интеллектуальный подход	Изменение
Точность (Precision)	0,45	0,92	+104%
Полнота (Recall)	0,82	0,86	+5%
F1-мера	0,70	0,89	+27%
Число ложных тревог (за 3 мес.)	847	312	–63%
Среднее время реакции оператора	12,4 мин	2,3 мин	–81%

Верификация на независимых данных (185 наблюдений) подтвердила устойчивость результатов. Модель сохранила абсолютную точность, не допустив ни одного ложноположительного срабатывания. F1-мера достигла значения 0,870, превысив результат тестовой выборки на 1,5%. Отсутствие деградации качества классификации подтверждает отсутствие переобучения модели и её пригодность для практического применения.

ЗАКЛЮЧЕНИЕ

В статье представлена методология интеллектуальной поддержки принятия решений при эксплуатации многослойных криогенных систем [17–19]. Разработан метод ручного дата-инжиниринга, включающий пятиэтапный регламент подготовки данных с учетом физических закономерностей предметной области. Формализован оператор преобразования признакового пространства Φ , расширяющий исходное пятимерное пространство измерений до восьмимерного на основе термодинамических соотношений [17, 20–21]. Разработана архитектура системы поддержки принятия решений с сохранением

функции окончательного решения за оператором. Обосновано применение SHAP-анализа для обеспечения интерпретируемости рекомендаций. Экспериментальная оценка на датасете из 730 наблюдений подтвердила повышение F1-меры с 0,653 до 0,925 при применении предложенного подхода. Модели случайного леса и градиентного бустинга достигли F1-меры 0,857 при полном отсутствии ложноположительных срабатываний. Внедрение системы на парке из 12 криогенных контейнеров обеспечило снижение числа ложных тревог на 63% и сокращение времени реакции оператора с 12,4 до 2,3 минуты.

Программный комплекс прошел государственную регистрацию (свидетельства № 2025614055 и № 2025684788) и функционирует в режиме промышленной эксплуатации с экономическим эффектом 7–10% снижения эксплуатационных затрат.

Авторы заявляют об отсутствии конфликта интересов.

The authors declare no conflict of interest.

ЛИТЕРАТУРА

1. Архаров А.М., Беляков В.П., Микулин Е.И. и др. Криогенные системы: учебник. М.: Машиностроение, 1987. 536 с.
2. Van Sciver S.W. Helium Cryogenics. New York: Springer Science. 2012. 470 p. DOI: 10.1007/978-1-4419-9979-5.
3. Филин Н.В., Буланов А.Б. Жидкостные криогенные системы. Л.: Машиностроение, 1985. 247 с.
4. Баранов А.Ю., Соколова Е.В. Хранение и транспортировка криогенных жидкостей. учебное пособие. СПб.: Университет ИТМО. 2017. 95 с.
5. Микулин Е.И. Криогенная техника. М.: Машиностроение, 1969. 272 с.
6. Бобков С.П., Галиаскаров Э.Г. Моделирование процесса теплопроводности с использованием систем клеточных автоматов. *Программные продукты и системы*. 2020. Т. 33. № 4. С. 641–650. DOI: 10.15827/0236-235X.132.641-650. EDN RFIURL.
7. 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.

REFERENCES

1. Arkharov A.M., Belyakov V.P., Mikulin E.I. et al. Cryogenic Systems: textbook. Moscow: Mashinostroenie. 1987. 536 p. (in Russian).
2. Van Sciver S.W. Helium Cryogenics. New York: Springer Science. 2012. 470 p. DOI: 10.1007/978-1-4419-9979-5.
3. Filin N.V., Bulanov A.B. Liquid Cryogenic Systems. Leningrad: Mashinostroenie. 1985. 247 p. (in Russian).
4. Baranov A.Yu., Sokolova E.V. Storage and Transportation of Cryogenic Liquids. Study Guide. St. Petersburg: ITMO University. 2017. 95 p. (in Russian).
5. Mikulin E.I. Cryogenic Engineering. Moscow: Mashinostroenie. 1969. 272 p. (in Russian).
6. Bobkov S.P., Galiaskarov E.G. Simulation of the heat conduction process using cellular automata systems. *Software & Systems*. 2020. Vol. 33. N 4. P. 641–650. DOI: 10.15827/0236-235X.132.641-650. (in Russian).
7. Astrakhanseva I.A., Gorev S.V., Astrakhansev R.G. Fractal-based analysis of efficiency and reliability in complex engineering systems. *Modern High Technologies. Regional Application*. 2023. N 4 (76), P. 60–68. (in Russian).

8. 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» [Ивэкофин]*. 2023. № 3 (57). С. 89-97.
9. 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.
10. Murphy K.P. Machine Learning: A Probabilistic Perspective. Cambridge: MIT Press. 2012. 28 p.
11. Учебник по машинному обучению. <https://education.yandex.ru/handbook/ml>.
12. Breiman L., Friedman J., Stone C.J., Olshen R.A. Classification and Regression Trees. Boca Raton: CRC Press, 1984.
13. Ho T.K. Random Decision Forests. *Materials of the 3rd International Conference on Document Analysis and Recognition*. Montreal: QC. 1995. P. 278-282.
14. Астраханцева И.А., Котенев Т.Е., Горев С.В., 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.
15. Астраханцева И.А., Котенев Т.Е., Горев С.В., Астраханцев Р.Г., Грименицкий П.Н. 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.
16. Астраханцева И.А., Котенев Т.Е., Горев С.В., Астраханцев Р.Г., Грименицкий П.Н. Метод градиентного бустинга при прогнозировании управленческих решений в многослойной криогенной системе. *Современные наукоемкие технологии. Региональное приложение*. 2024. № 2 (78). С. 50-58.
17. Астраханцева И.А., Котенев Т.Е., Горев С.В., 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.
18. Горев С.В., Астраханцева И.А. Многослойная система как объект структурного управленческого и адаптивного моделирования в системном анализе. В сб. «Имитационное моделирование. Теория и практика (ИММОД-2025)» 12 Всерос. н.-пр. конференции. СПб.: АО «ЦТСС». 2025. С. 652-658.
19. Горев С.В., Астраханцева И.А. Простые модели машинного обучения для прогнозирования и поддержки управленческих решений в многослойных криогенных системах. В сб. «Прикладной искусственный интеллект: перспективы и риски II Межд. науч. конференции. СПб.: ГУАП. 2025. С. 197-202.
20. Гордина Н.Е., Мельников А.А., Гусев Г.И., Гушин 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.
21. 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.
8. Astrakhantseva I.A., Gorev S.V., Astrakhantsev R.G. Systems approach to the analysis of the fractal nature of complex technical systems. *Ivecofin*. 2023. N 3 (57). P. 89-97. (in Russian).
9. Morozov E.N., Gorev S.V. Mathematical models for optimization of machine-readable regulation. *Ivecofin*. 2023. N 4 (58). P. 71-78. (in Russian).
10. Murphy K.P. Machine Learning: A Probabilistic Perspective. Cambridge: MIT Press. 2012. 28 p.
11. Machine Learning Handbook. <https://education.yandex.ru/handbook/ml>. (in Russian).
12. Breiman L., Friedman J., Stone C.J., Olshen R.A. Classification and Regression Trees. Boca Raton: CRC Press. 1984.
13. Ho T.K. Random Decision Forests. *Materials of the 3rd International Conference on Document Analysis and Recognition*. Montreal: QC. 1995. P. 278-282.
14. Astrakhantseva I.A., Kotenev T.E., Gorev S.V., Astrakhantsev R.G., Grimenitsky P.N. Integration of linear regression and random forest methods into intelligent support systems for managing cryogenic transport systems. *Ivecofin*. 2024. N 3 (61). P. 81-90. (in Russian).
15. Astrakhantseva I.A., Kotenev T.E., Gorev S.V., Astrakhantsev R.G., Grimenitsky P.N. Artificial intelligence in management of multilayer cryogenic system with vacuum insulation and liquid nitrogen cooling shield. *Modern High Technologies. Regional Application*. 2024. N 1 (77). P. 50-59. (in Russian).
16. Astrakhantseva I.A., Kotenev T.E., Gorev S.V., Astrakhantsev R.G., Grimenitsky P.N. Gradient boosting method in predicting management decisions in the multilayer cryogenic systems. *Modern High Technologies. Regional Application*. 2024. N 2 (78). P. 50-58. (in Russian).
17. Astrakhantseva I.A., Kotenev T.E., Gorev S.V., Astrakhantsev R.G. Optimization of operation of multilayer cryogenic systems using machine learning methods and standardized implementation protocols. *Modern High Technologies. Regional Application*. 2025. N 2 (82). P. 59-70. (in Russian).
18. Gorev S.V., Astrakhantseva I.A. A Multilayer System as an Object of Structural Managerial and Adaptive Modeling in Systems Analysis. *Materials of the 12th All-Russian scientific-practical conference «Simulation Modeling. Theory and Practice (IMMOD-2025)»*. St. Petersburg: JSC "CTSS". 2025. P. 652-658. (in Russian).
19. Gorev S.V., Astrakhantseva I.A. Simple machine learning models for forecasting and supporting managerial decisions in multilayer cryogenic systems. *Materials of the II International Scientific Conference «Applied Artificial Intelligence: Prospects and Risks»*. St. Petersburg: SUAI. 2025. P. 197-202. (in Russian).
20. Gordina N.E., Melnikov A.A., Gusev G.I., Gushchin A.A., Rumyantsev R.N., Astrakhantseva I.A. Mechanochemical and plasmochemical processing in the synthesis of catalytic systems based on vermiculite and zirconium oxychloride. *ChemChemTech*. 2022. Vol. 65. N 5. P. 43-57. DOI: 10.6060/ivkkt.20226505.6612. (in Russian).
21. Bobkov S.P., Astrakhantseva I.A., Gushchin A.A. et al. Using a discrete probabilistic approach for simulating flow tubular reactors. *ChemChemTech*. 2025. Vol. 68. N 2. P. 96-101. DOI: 10.6060/ivkkt.20256802.7109. (in Russian).

Поступила в редакцию 28.11.2025
Принята к опубликованию 12.12.2025

Received 28.11.2025
Accepted 12.12.2025