


Федеральное государственное бюджетное образовательное учреждение высшего образования «Ивановский государственный химико-технологический университет»

На правах рукописи



Горев Сергей Владимирович

**МОДЕЛИ И АЛГОРИТМЫ ИНТЕЛЛЕКТУАЛЬНОГО
УПРАВЛЕНИЯ МНОГОСЛОЙНОЙ КРИОГЕННОЙ СИСТЕМОЙ**

Специальность 2.3.1 – «Системный анализ, управление и обработка информации, статистика» (технические науки)

Диссертация
на соискание учёной степени
кандидата технических наук

Научный руководитель:
доктор экономических наук, доцент
Астраханцева Ирина Александровна

Иваново – 2026

Оглавление

Введение.....	4
1 Анализ методов и алгоритмов обработки информации в системах управления криогенными техническими объектами	13
1.1 Многослойная криогенная система как объект управления и обработки информации	13
1.2 Анализ методов обработки информации и интеллектуального управления в криогенных технических системах	25
1.3 Обоснование требований к методам решения задачи и постановка научной задачи исследования	35
Выводы по главе 1.....	44
2 Физико-математическая постановка задачи обработки информации в системе управления многослойной криогенной системой.....	46
2.1 Анализ применимости детерминированного подхода к задаче определения состояния экранирующего слоя.....	46
2.2 Математическая модель классификации состояний многослойной криогенной системы как задача многокритериальной оптимизации с ограничениями.....	59
2.3 Формализация задачи формирования признакового пространства и отбор допустимых моделей классификации	71
Выводы по главе 2.....	80
3 Алгоритмы формирования признакового пространства и интеллектуальной поддержки принятия решений	83
3.1 Алгоритм формирования признакового пространства	83
3.2 Алгоритм интеллектуальной поддержки принятия решений	98
3.3 Функциональная модель системы поддержки принятия решений и алгоритм адаптации модели.....	105
Выводы по главе 3.....	115
4 Экспериментальная оценка и апробация разработанных моделей и алгоритмов	118

4.1 Архитектура программного комплекса интеллектуальной поддержки управления	118
4.2 Экспериментальная оценка алгоритмов на данных сенсорных систем криогенных контейнеров.....	129
4.3 Результаты адаптации модели и промышленной эксплуатации.....	137
Выводы по главе 4.....	144
Заключение	147
Список сокращений и условных обозначений.....	152
Список литературы	153
Приложение А (справочное) Акты об использовании и внедрении результатов диссертационного исследования	166

Введение

Актуальность темы исследования. Многослойная криогенная система (МКС) относится к сложным техническим системам, обеспечивающим транспортировку сжиженных газов при температурах, близких к абсолютному нулю. В её конструкцию входят внутренний резервуар с жидким гелием (4,2 К), промежуточный экранирующий слой жидкого азота (77 К) и вакуумная изоляция. Азотный экран выполняет функцию основного элемента теплозащиты: при его утрате теплоприток к гелиевому контуру возрастает на два порядка, вследствие чего начинается интенсивное испарение продукта. В связи с этим основной задачей оперативного управления МКС в процессе транспортировки выступает своевременное определение момента долива жидкого азота.

Управление МКС реализуется посредством бортового контроллера на базе микропроцессора STM32, установленного на раме контейнера-цистерны. На контроллер поступают показания пяти датчиков арматурного узла: уровня и давления гелия, уровня и давления азота, а также статуса контейнера. При этом вычислительные ресурсы контроллера ограничены – объём памяти составляет 256 КБ, время обработки данных не должно превышать 50 мс, постоянный канал связи с диспетчерским центром отсутствует. 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 автоматизированной обработки информации. Такой подход не учитывает совместную динамику параметров контролируемых сред и не обеспечивает количественного обоснования принимаемых решений.

Таким образом, актуальной научной задачей является разработка моделей и алгоритмов классификации состояний МКС в условиях ограниченных

вычислительных ресурсов встраиваемого контроллера при существенном дисбалансе классов и асимметрии последствий ошибок классификации. Не разработаны алгоритмы формирования признакового пространства, формализующие физические соотношения между параметрами контролируемых сред для повышения разделимости классов в рамках указанных ограничений, не разработаны алгоритмы представления результатов классификации, обеспечивающие переход от результата модели к верифицируемому управленческому решению оператора, а также отсутствуют модели системы поддержки принятия решений, формализующие полный цикл обработки информации от сбора данных до формирования управленческого решения с механизмом адаптации на эксплуатационных данных.

Степень разработанности научной задачи. Теоретическими основами криогенной техники и физикой криогенных процессов занимались такие учёные, как Архаров А.М., Беляков В.П., Микулин Е.И., Van Sciver S.W. Вопросы теплопередачи в многослойных системах изоляции исследовались Зарубиным В.С. Процессы тепло- и массообмена моделировались в работах Пасконова В.М., Полежаева В.И. и Чудова Л.А.

Применение методов прогностики и интеллектуального анализа данных к задачам управления техническими системами исследовали Saha B. и Goebel K. (байесовская прогностика для мониторинга оборудования), Daigle M.J. (модельная прогностика с конкурирующими процессами деградации), Gebraeel N. (прогнозирование остаточного ресурса на основе нейронных сетей). Управление криогенными системами ускорителя элементарных частиц рассматривалось в работах Pezzetti M.

Теоретические основы обработки информации в технических системах и методы системного анализа для задач принятия решений развивались в работах Shannon C.E. (математическая теория информации), Wald A. (статистическая теория принятия решений), Советова Б.Я. (теория информационных процессов и систем), Юсупова Р.М. (управление сложными информационными системами),

Новикова Д.А. (теория принятия решений и управления), Монахова М.Ю., Астраханцевой И.А., Бобкова С.П.

Подходы к интеграции физических знаний в модели машинного обучения развивались в работах Raissi M. и Karniadakis G.E. Вопросы интерпретируемости моделей машинного обучения рассматривались в работах Lundberg S.M. и Lee S.-I., Ribeiro M.T. и других. Развертыванием моделей на встраиваемых системах с ограниченными вычислительными ресурсами занимался Warden P.

Вместе с тем в известных работах не решена задача формирования признакового пространства с учётом физики процессов теплопереноса для встраиваемых систем с ограниченными ресурсами. Не разработаны алгоритмы представления результатов классификации, обеспечивающие интерпретируемость и переход к верифицируемому управленческому решению оператора в условиях ограничений бортового контроллера. Отсутствуют модели системы поддержки принятия решений, формализующие полный цикл обработки информации от сбора данных до формирования управленческого решения с механизмом адаптации на эксплуатационных данных.

Целью диссертационного исследования является повышение качества и оперативности обработки информации интеллектуального управления многослойной криогенной системой за счёт разработки моделей и алгоритмов на основе многокритериальной оптимизации с ограничениями.

Достижение указанной цели обусловило постановку и решение следующих задач:

1. Разработать алгоритм формирования признакового пространства для задачи оптимизации распознавания состояний многослойной криогенной системы при ограничениях на вычислительные ресурсы встраиваемого контроллера, включающий оператор преобразования признаков на основе физических соотношений между параметрами контролируемых сред.

2. Разработать алгоритм интеллектуальной поддержки принятия решений для управления многослойной криогенной системой, включающий модель

классификации состояний и алгоритм представления результатов классификации, обеспечивающий интерпретируемость решений для оператора.

3. Разработать функциональную модель системы поддержки принятия решений для управления многослойной криогенной системой, формализующую технологический процесс обработки информации от сбора данных до формирования управленческого решения оператором.

4. Провести экспериментальную оценку и верификацию разработанных моделей и алгоритмов на реальных данных сенсорных систем криогенных контейнеров, включая сравнение с существующим подходом на основе ручного контроля.

Объектом исследования является система управления многослойной криогенной системой.

Предметом исследования является технологический процесс обработки информации в системе управления многослойной криогенной системой.

Методология и методы исследования. Научные положения работы теоретически обосновываются при помощи аппарата теории вероятностей, математической статистики, математического анализа, многокритериальной оптимизации, теории обработки информации и физических моделей теплопереноса. Для экспериментальной проверки работоспособности предложенных алгоритмов использовалось разработанное программное обеспечение.

Научная новизна результатов диссертационного исследования заключается в разработке моделей и алгоритмов интеллектуальной поддержки принятия решений для управления многослойной криогенной системой, обеспечивающих автоматизированную обработку сенсорной информации и формирование верифицируемых управленческих решений оператора в условиях ограниченных вычислительных ресурсов встраиваемых контроллеров.

Научная новизна диссертационного исследования состоит в следующем:

1. Разработан алгоритм формирования признакового пространства для задачи оптимизации распознавания состояний многослойной криогенной системы

при ограничениях на вычислительные ресурсы встраиваемого контроллера, отличающийся тем, что включает оператор преобразования признаков, который отображает исходное n -мерное пространство сенсорных измерений в расширенное M -мерное пространство ($M > n$) путем генерации производных признаков на основе физических соотношений между параметрами контролируемых сред, а также количественную валидацию вклада производных признаков через аддитивную декомпозицию решений модели (соответствует п. 4 паспорта специальности).

2. Разработан алгоритм интеллектуальной поддержки принятия решений для управления многослойной криогенной системой, включающий модель классификации состояний на расширенном признаковом пространстве, оптимизированную с учётом асимметрии последствий ошибок классификации и дисбаланса классов, и алгоритм представления результатов классификации, обеспечивающий формирование интерпретируемых рекомендаций для оператора с декомпозицией вклада каждого признака в решение модели. В отличие от существующего ручного управления, при котором оператор принимает решение на основе 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 с указанием факторов, определивших решение модели, что обеспечивает переход от субъективной оценки к верифицируемому решению оператора (п. 10 паспорта специальности).

3. Разработана функциональная модель системы поддержки принятия решений управления многослойной криогенной системой, формализующая технологический процесс обработки информации от сбора данных до формирования управленческого решения оператором, отличающаяся тем, что реализует супервизорную архитектуру управления, где алгоритмическая обработка информации дополняется интерпретацией результатов для оператора и механизмом адаптации модели на эксплуатационных данных с двухкритериальной валидацией, учитывающей асимметрию последствий ошибок (п. 9 паспорта специальности).

На защиту выносятся следующие положения и результаты, обладающие научной новизной:

1. Разработанный алгоритм формирования признакового пространства для задачи оптимизации распознавания состояний многослойной криогенной системы при ограничениях на вычислительные ресурсы встраиваемого контроллера, включающий оператор преобразования признаков, который отображает исходное n -мерное пространство сенсорных измерений в расширенное M -мерное пространство ($M > n$) на основе физических соотношений между параметрами контролируемых сред, обеспечивает повышение F_1 -меры классификации состояний с $0,653 \pm 0,087$ до $0,925 \pm 0,021$ (пятикратная кросс-валидация, критерий Уилкоксона $W = 15$, $p = 0,031$). Производные признаки обеспечивают 78 % суммарного вклада в решения модели.

2. Разработанный алгоритм интеллектуальной поддержки принятия решений, включающий модель классификации состояний на расширенном признаковом пространстве и алгоритм представления результатов классификации с декомпозицией вклада каждого признака, позволяет сократить время реакции оператора с 204 до 2,3 минуты и снизить долю ложных срабатываний с 4,9 % до 0,6 % по сравнению с существующим ручным управлением.

3. Разработанная функциональная модель системы поддержки принятия решений, формализующая технологический процесс обработки информации для управления многослойной криогенной системой с сохранением за оператором функции окончательного решения и механизмом адаптации с двухкритериальной валидацией (F_1 и Recall), обеспечивает повышение F_1 -меры с 0,46 (ручной контроль) до 0,89 и поддержание F_1 фактически не ниже 0,880 при установленном пороге 0,875 при эксплуатации в течение 18 месяцев. Модель реализована в ограничениях встраиваемой системы (время инференса не более 20 мс, размер модели не более 120 КБ).

Соответствие диссертации паспорту научной специальности.
Проблематика, исследованная в диссертации, соответствует пунктам 4, 9, 10

паспорта специальности 2.3.1 «Системный анализ, управление и обработка информации, статистика».

Теоретическая значимость исследования заключается в развитии подходов к формированию признакового пространства для задач классификации в условиях ограниченных вычислительных ресурсов. Предложенный алгоритм формирования признаков на основе физических соотношений между параметрами контролируемых сред расширяет инструментарий обработки информации для встраиваемых систем управления. Разработанная функциональная модель системы поддержки принятия решений с механизмом адаптации на эксплуатационных данных и двухкритериальной валидацией может быть использована при построении аналогичных систем для других технических объектов с ограниченными вычислительными ресурсами, в том числе в химической промышленности, энергетике и транспорте.

Практическая значимость работы определяется внедрением результатов в систему управления парком криогенных контейнеров. Разработанные алгоритмы реализованы в двух программных продуктах: программа интеллектуальной поддержки принятия решений для управления многослойной криогенной системой (свидетельство № 2025614055 [125]) и программа для сбора и обработки данных многослойной криогенной системы (свидетельство № 2025684788 [126]). Внедрение обеспечило повышение F_1 -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 % (в 8,2 раза). Результаты внедрены на промышленных предприятиях, что подтверждено соответствующими актами. Результаты диссертационного исследования используются в учебном процессе ИГХТУ при преподавании дисциплин «Теория информации, данные, знания», «Технология обработки информации», «Информационные технологии», «Модели информационных процессов и систем», что подтверждено актом внедрения.

Достоверность и обоснованность научных положений и выводов обеспечивается формализацией задачи классификации как задачи многокритериальной оптимизации с ограничениями, применением обоснованных

методов статистического анализа и верификацией на реальных данных. Качество классификации оценено методом стратифицированной пятикратной кросс-валидации ($F_1 = 0,925 \pm 0,021$, коэффициент вариации 2,3 %). Статистическая значимость различий между моделями подтверждена критерием Уилкоксона для связанных выборок ($W = 15$, $p = 0,031 < 0,05$). Отсутствие переобучения подтверждено верификацией на независимой выборке из 185 наблюдений, не участвовавших в обучении ($F_1 = 0,870$, относительное отклонение в $-5,9\%$ от результата кросс-валидации (0,925) и $+1,5\%$ от значения F_1 на тестовой выборке исходного пространства $R^5 = 0,857$). Сравнение с существующим ручным контролем выполнено на основе анализа эксплуатационных журналов и экспертных оценок инженерного персонала. Работоспособность системы и механизма адаптации подтверждена в условиях промышленной эксплуатации парка криогенных контейнеров.

Апробация результатов исследования. Положения и выводы диссертации прошли апробацию на международных и всероссийских научно-практических конференциях: Всероссийская школа-конференция молодых учёных «Дни науки в ИГХТУ» (22–26.04.2024, ИГХТУ); V Международная научно-практическая конференция «Построение систем управления устойчивым развитием территорий: взаимодействие стран БРИКС» (15–17.05.2025, МГУ имени М.В. Ломоносова); V Всероссийская научно-практическая конференция «Актуальные проблемы функционирования финансовой системы России» (27.02.2025, Финансовый университет); Всероссийская конференция с международным участием «Имитационное моделирование. Теория и практика» (ИММОД) (15–17.10.2025, Санкт-Петербург); Международная конференция «Прикладной искусственный интеллект: перспективы и риски» (21.10.2025, Санкт-Петербург); Международная научно-практическая конференция «Теория и практика применения вычислительных и информационных технологий в отраслевых системах» (COMSYSTEM 2026) (13–14.03.2026, МТУСИ).

Научно-практическая значимость работы подтверждена рецензируемыми публикациями в журналах и в сборниках научных трудов, докладами на научных

конференциях международного и российского уровня, свидетельствами о государственной регистрации программ для ЭВМ. Практическая значимость работы подтверждена внедрением её результатов в ООО «ИнфраПро» г. Москва, АО «Инвест-Альянс» г. Москва, АО «Ивхимпром» г. Иваново, а также в учебном процессе ИГХТУ.

Публикация результатов исследования. По теме диссертационного исследования опубликовано 13 научных работ, в том числе 9 – в журналах, рекомендованных ВАК РФ (общим объемом 5,7 печатных листов), получено 2 свидетельства о государственной регистрации программы для ЭВМ.

Личный вклад. Все результаты, изложенные в диссертации, получены автором лично. Постановка цели и задач, обсуждение планов исследований и полученных результатов выполнены совместно с научным руководителем.

Структура и объем диссертации. Диссертация состоит из введения, четырёх глав с выводами, заключения и списка литературы. Работа содержит 165 страниц основного текста, 35 рисунков, 26 таблиц, 1 приложение. Список литературы включает 126 наименований. Оформление библиографических ссылок выполнено в соответствии с ГОСТ Р 7.0.5-2008 [5].

1 Анализ методов и алгоритмов обработки информации в системах управления криогенными техническими объектами

1.1 Многослойная криогенная система как объект управления и обработки информации

Многослойные криогенные системы представляют собой сложные технические объекты, используемые в различных отраслях промышленности. С позиций системного подхода такие объекты удобно описывать как набор взаимосвязанных компонентов, каждый из которых наделён определённой функцией и местом в структуре. Подход хорошо себя показывает там, где задачи управления, прогнозирования и оценки эффективности приходится формализовать. Если применить его к МКС, в её составе обнаруживаются: внутренний криогенный резервуар с жидким гелием, промежуточный азотный экран, вакуумная изоляция, измерительные датчики, исполнительные механизмы и блок управления. Всё это связано функционально – именно за счёт связей система согласованно работает при экстремально низких температурах [9].

Сегодня криогенные системы используются в магнитно-резонансной томографии, при хранении биологических образцов, в аэрокосмической отрасли – для хранения и транспортировки топлива космических аппаратов.

В научных исследованиях гелий выступает охлаждающим агентом для достижения температур вблизи абсолютного нуля, что приобретает критическое значение в экспериментах по изучению квантовых явлений и сверхпроводимости. Его свойства при низких температурах, в том числе сверхтекучесть, делают гелий значимым инструментом фундаментальных физических исследований [24; 25; 26]. Работа таких систем протекает при экстремально низких температурах, как правило ниже минус 150 градусов Цельсия, и требует применения передовых технологий и стратегий управления для поддержания стабильных условий работы и минимизации теплопритоков.

К физическим процессам, протекающим в многослойных криогенных системах, относятся охлаждение гелия до экстремально низких температур, сохранение гелия в жидком агрегатном состоянии, создание и поддержание вакуума для снижения теплопередачи, а также использование азота в качестве хладагента для уменьшения теплопритоков [24]. Температура кипения гелия при нормальном атмосферном давлении равна 4,2 К (минус 268,9 градусов Цельсия); по этому показателю гелий – самый холодный среди промышленных криогенных агентов. Достижение таких температур обеспечивается циклом охлаждения, в основе которого лежат принципы термодинамики – адиабатическое расширение и эффект Джоуля-Томсона. На первом этапе цикла гелий сжимается при высоких температурах и пропускается через теплообменник, после чего наступает стадия адиабатического расширения со снижением температуры. Далее включается джоулево-томсоновский процесс. Гелий пропускают через пористое сопло (или дроссель), на нём возникает перепад давления, и за счёт внутреннего энергетического обмена температура падает ещё ниже. В каскадных охлаждающих системах эта последовательность повторяется многократно: только так удаётся выйти на криогенный уровень и перевести гелий в жидкое состояние [27].

Спрос на гелий из года в год растёт. Перевозят его в специализированных контейнерах, способных удерживать низкие температуры и не допустить утечек. По сути это криогенные резервуары: они изолируют гелий от внешних температурных воздействий и сводят тепловые притоки к минимуму – без этого сжиженный гелий просто не дойдёт до места назначения. Вакуумная изоляция и многослойные изолирующие материалы заметно снижают теплопередачу через излучение, конвекцию и проводимость. Сохранность гелия при транспортировке дополнительно обеспечивается системами контроля утечек и давления – они отслеживают состояние продукта и предотвращают его потери, что особенно важно с учётом высокой стоимости и стратегического значения этого ресурса.

Поддержание температурных показателей в заданных пределах давления относится к ключевым факторам эффективности криогенных систем. Любое

ухудшение качества вакуума ведёт к росту теплопритоков и сказывается на производительности системы. Именно поэтому мониторинг и поддержание целостности вакуума определяют долгосрочную надёжность криосистем. Материалы конструкции криогенных систем подбираются с учётом их свойств при низких температурах – теплового сжатия, прочности, теплопроводности. При этом материалы, показывающие благоприятные характеристики при комнатной температуре, в криогенных условиях нередко ведут себя иначе, что может приводить к неэффективности или сбоям в работе системы.

Классификация криогенных систем строится по их конструкции и принципу действия. Системы с вакуумной изоляцией устроены так, что криогенный материал находится в сосуде, помещённом в вакуумную камеру, – такая компоновка существенно снижает теплопередачу конвекцией и проводимостью. В многослойных изоляционных системах между внутренним сосудом и вакуумной камерой чередуются отражающие и непроводящие материалы, что сводит к минимуму теплопередачу излучением. Системы с жидким азотом имеют дополнительный слой охлаждения, в котором жидкий азот поглощает поступающее тепло. Криостаты представляют собой системы, предназначенные для поддержания низких температур в течение длительного времени, часто используя комбинацию перечисленных методов изоляции и охлаждения. Каждый из этих типов криогенных систем оптимизирован для конкретного применения, требующего надёжного и эффективного охлаждения до крайне низких температур.

В настоящем исследовании анализируется многослойная криогенная система с вакуумной изоляцией и охлаждаемая жидким азотом. Схема системы представлена на Рисунке 1.1.




Рисунок 1.1 – Многослойная криогенная система с вакуумной изоляцией и азотным экраном

Многослойная криогенная система с вакуумной изоляцией и охлаждаемая жидким азотом состоит из нескольких компонентов, обеспечивающих эффективное охлаждение и изоляцию. Основная структура системы включает внутренний сосуд, содержащий криогенный материал, в данном случае жидкий гелий при температуре 4,2 К. Он окружен вакуумной камерой для минимизации теплопередачи конвекцией и проводимостью. Между внутренним сосудом и вакуумной камерой находятся многослойные изоляционные материалы, состоящие из чередующихся слоев отражающего и непроводящего материалов (металлизированная полимерная пленка и стекловолоконные прокладки). Эти слои существенно уменьшают теплопередачу излучением, что критически важно при крайне низких температурах. Внешний сосуд системы содержит жидкий азот, который используется для дополнительного охлаждения. Жидкий азот с температурой кипения около минус 196 градусов Цельсия (77 К) эффективно охлаждает теплозащитный экран, размещенный между внутренним криогенным

сосудом для гелия и вакуумной рубашкой, снижая температуру внутри криогенной системы и способствуя поддержанию высокого вакуума.

Многослойные криогенные системы с вакуумной изоляцией и азотным экраном используются в контейнерах-цистернах для перевозки жидкого гелия. Объектом настоящего исследования выступает транспортная многослойная криогенная система на базе контейнеров типа HE 4116-30-06-N производства компании CRYO AB. Парк из двенадцати таких контейнеров-цистерн, перевозимых автомобильными тягачами КАМАЗ, обеспечивает доставку жидкого гелия потребителям на расстояния до нескольких тысяч километров. Основные технические характеристики контейнера-цистерны для перевозки жидкого гелия типа HE 4116-30-06-N представлены в Таблице 1.1 [28].

Таблица 1.1 – Основные технические характеристики контейнера-цистерны для перевозки жидкого гелия типа HE 4116-30-06-N

Характеристика	Значение
Рабочее давление емкости для гелия	0,6 МПа
Расчетное давление емкости для гелия	0,6 МПа
Рабочее давление емкости для азота	0,07 МПа
Расчетное давление емкости для азота	0,17 МПа
Давление гидравлического испытания (гелий)	0,91 МПа
Давление гидравлического испытания (азот)	0,3 МПа
Рабочая температура внутреннего корпуса	минус 269 градусов Цельсия
Рабочая температура вакуумной рубашки	от минус 50 до плюс 50 градусов Цельсия
Объем емкости для гелия (в холодном состоянии)	40 м ³
Объем емкости для азота	1,65 м ³
Масса пустого сосуда	16 000 кг
Максимальная масса заливаемого гелия	4 610 кг
Максимальная масса заливаемого азота	1 310 кг
Расчетный срок службы	30 лет

Контейнер-цистерна данного типа представляет собой многослойную криогенную систему с вакуумной изоляцией и азотным экраном, предназначенную для перевозки жидкого гелия. Конструкция включает емкости для хранения жидкого гелия и жидкого азота, где внутренний корпус адаптирован для работы при крайне низких температурах, достигающих минус 269 градусов Цельсия, а вакуумная рубашка обеспечивает защиту, функционируя в температурном диапазоне от минус 50 до плюс 50 градусов Цельсия. Отсутствие прибавки на компенсацию коррозии и эрозии указывает на использование материалов, обладающих высокой устойчивостью к воздействию криогенных сред.

Рабочее и расчётное давление зависят от среды. Для гелиевой ёмкости рабочее давление равно расчётному и составляет 0,6 МПа. Для жидкого азота рабочее давление – 0,07 МПа, расчётное – 0,17 МПа; такой запас по давлению нужен, чтобы конструкция азотного экрана сохраняла устойчивость во время эксплуатации. Испытания проводят при давлениях выше рабочих – это подтверждает надёжность системы под критическими нагрузками. Объём гелиевой ёмкости в холодном состоянии – 40 м³, азотной – 1,65 м³. Пустой сосуд весит 16 000 кг, предельная масса заливаемой среды – до 4 610 кг гелия и 1 310 кг азота. Расчётный срок службы контейнера-цистерны – 30 лет; столько работают конструкции, рассчитанные на длительную эксплуатацию.

Ключевая особенность задачи управления – пороговый эффект при потере азотного экрана. В штатном режиме жидкий азот удерживает перепад в 73 К: 77 К на внутренней стороне экрана и около 150 К на внешней. На него ложится основная часть теплового потока из окружающей среды. Скорость испарения азота в штатных условиях составляет от 3 до 7 процентов в сутки в зависимости от температуры внешней среды и состояния изоляции. При снижении уровня жидкого азота до нуля экранирующий слой перестает функционировать, и теплоприток к гелиевому сосуду возрастает приблизительно в 250 раз. Такое скачкообразное изменение теплового режима приводит к лавинообразному испарению гелия и может повлечь за собой потерю всего содержимого контейнера в течение

нескольких часов. Все газы, кроме гелия, замерзают при его рабочей температуре, поэтому попадание примесей в систему чрезвычайно опасно и может вызвать закупорку контрольно-измерительных приборов и предохранительных устройств. При транспортировке необходимо также учитывать преобразование кинетической энергии от вибраций, ударов и подобных воздействий в тепловую энергию, что при отсутствии надлежащего контроля ведет к повышению внутренних температур [28].

Управление многослойной криогенной системой требует точного контроля температуры и давления внутри системы для обеспечения эффективной и безопасной работы. Необходимо поддерживать высокую степень вакуума в вакуумной рубашке, что минимизирует теплопередачу и обеспечивает эффективную изоляцию. Мониторинг температуры внутри криогенного сосуда и в слое жидкого азота осуществляется с помощью датчиков. Регулирование давления и температуры ведётся средствами автоматического управления, которые подают или отводят криогенные жидкости и газы для поддержания заданных параметров. Одновременно необходим контроль целостности изоляционных слоёв и их эффективности: без него невозможно предотвратить тепловые притоки и сохранить работоспособность системы на требуемом уровне.

В управлении криогенными системами задействован ряд технологий автоматизации. Для поддержания нужных параметров с высокой точностью применяется пропорционально-интегрально-дифференцирующий регулятор. Управляющий сигнал, формируемый таким регулятором, представляет собой сумму трёх слагаемых; в зависимости от конкретной ситуации используются различные конфигурации регулятора, однако базовым законом управления остаётся пропорциональный. Теоретические основания синтеза регуляторов этого типа раскрыты в фундаментальных работах по теории автоматического управления [75; 100]; методы прогнозирующего управления на основе моделей, дающие возможность учитывать динамику объекта при выработке управляющих воздействий, систематизированы в [66]. Программируемые логические контроллеры обеспечивают выполнение алгоритмов управления и взаимодействие

с датчиками и исполнительными механизмами. Системы диспетчерского управления и сбора данных охватывают уровни наблюдения, управления и измерения криогенными системами. В дополнение к классическим функциям таких систем за последнее десятилетие был добавлен ряд новых функций, включая визуализацию иерархии процессов, доступ к блокировкам для каждого устройства, автоматическую настройку контура управления, прямой доступ к документации по устройствам [18].

С позиций теории обработки информации транспортная многослойная криогенная система может быть представлена как информационная система, реализующая полный цикл от сбора первичных измерений до формирования управляющего решения. Процесс управления МКС включает последовательность этапов, характерную для любой информационной системы, а именно сбор данных от сенсорных устройств, передачу данных на обрабатывающее устройство, обработку и анализ полученных измерений и формирование решения на основе результатов обработки. Структурная схема системы управления МКС как информационной системы представлена на Рисунке 1.2.

Сенсорная подсистема, размещенная на арматурном узле контейнера, обеспечивает измерение пяти физических параметров, характеризующих текущее состояние МКС. Уровень жидкого гелия и давление в гелиевом контуре совместно характеризуют термодинамическое состояние основного криогенного продукта. Уровень жидкого азота и давление в азотном контуре описывают состояние защитного экрана. Статус контейнера фиксирует режим эксплуатации, существенно влияющий на интенсивность тепловых процессов из-за различий в вибрационных нагрузках.




Рисунок 1.2 – Структурная схема системы управления МКС как информационной системы

Состав сенсорной подсистемы и метрологические характеристики датчиков приведены в Таблице 1.2.

Таблица 1.2 – Параметры сенсорной подсистемы МКС

Параметр	Тип датчика	Диапазон измерения	Погрешность	Интерфейс
Уровень жидкого гелия	Сверхпроводящий	0–100 %	±1 %	Аналоговый 4–20 мА
Давление гелия	Тензометрический	0–0,5 МПа	±0,5 %	Аналоговый 4–20 мА
Уровень жидкого азота	Емкостной	0–100 %	±1 %	Аналоговый 4–20 мА
Давление азота	Пьезорезистивный	0–1,0 МПа	±0,5 %	Аналоговый 4–20 мА

Параметр	Тип датчика	Диапазон измерения	Погрешность	Интерфейс
Статус контейнера (в пути или в покое)	Акселерометрический	Бинарный	–	Цифровой

Данные от датчиков поступают на бортовой контроллер по проводным линиям в стандарте 4–20 мА длиной до трёх метров. Контроллер размещен в защищенном корпусе на раме контейнера-цистерны. Обработанная информация может быть передана на планшетный компьютер водителя по беспроводному каналу малой дальности, обеспечивающему устойчивую связь на расстоянии 10–30 метров. Бортовой контроллер семейства STM32 работает в условиях жёстких ресурсных ограничений: всего 256 КБ оперативной памяти, не более 50 мс на цикл опроса датчиков и формирования результата, постоянной связи с внешними вычислительными ресурсами нет. Эти три условия вместе определяют, какие алгоритмы обработки информации в принципе допустимы, и сразу отсекают методы, требующие либо больших вычислительных мощностей, либо постоянного обращения к внешним серверам.

Принятие решений при эксплуатации транспортной криогенной системы устроено сегодня в основном вручную. Примерно раз в четыре часа водитель останавливается на маршруте, считывает с арматурного узла показания манометров и уровнемеров, фотографирует приборную панель и отправляет снимки инженеру через мессенджер. Инженер сидит в диспетчерском центре, ведёт сразу несколько контейнеров и по полученной фотографии – опираясь на свой опыт – решает, нужен ли долив жидкого азота. Этот процесс обладает рядом существенных недостатков с точки зрения обработки информации.

Оценка состояния системы не формализована, поскольку инженер принимает решение на основе визуального восприятия статичного изображения приборов, а не на основе количественного анализа динамики параметров. Он не видит тренды изменения параметров во времени, не имеет возможности сопоставить текущие значения с историей предшествующих измерений. Фактически весь объем

информации, доступной для принятия решения, сводится к мгновенному снимку пяти величин, причем качество этого снимка зависит от условий фотографирования. Различные специалисты при одних и тех же показаниях приборов могут прийти к противоположным заключениям, поскольку более опытный инженер учитывает неявные факторы (время года, возраст контейнера, историю предшествующих доливов жидкого азота), тогда как менее опытный склонен к перестраховке, что порождает избыточное количество ложных рекомендаций о доливе. Каждая такая рекомендация влечет незапланированную остановку транспортного средства, простой тягача и нарушение графика доставки.

Временные задержки в цепочке принятия решений складываются из ожидания плановой остановки водителем, фотографирования приборов и передачи изображения по каналу мобильной связи (который на отдельных участках маршрута может отсутствовать), анализа данных инженером и формулирования рекомендации. Суммарная задержка от момента возникновения критического изменения параметров до получения водителем указания может составлять несколько часов, что при пороговом эффекте потери азотного экрана представляет существенный риск утраты дорогостоящего груза.

Достижение высокой точности, надежности и энергоэффективности в условиях экстремальных температур в управлении криогенными системами является актуальной научной и промышленной задачей. Требования к качеству программных и аппаратных компонентов таких систем могут быть формализованы с использованием международного стандарта качества [2], определяющего характеристики функциональной пригодности, надежности, производительности и безопасности. Основные проблемы связаны с поддержанием стабильных температурных режимов, предотвращением физического износа оборудования, минимизацией рисков тепловых утечек и сбоев системы, а также со сложностью диагностики. Проблема теплопередачи и тепловых притоков обусловлена необходимостью минимизации теплопередачи, которая происходит посредством трёх механизмов (теплопроводности, конвекции и излучения), и любые нарушения в изоляции приводят к увеличению тепловых притоков. Проблема контроля

параметров рабочей среды связана с необходимостью точного мониторинга температуры, давления и состояния изоляции, причем особую сложность представляет управление многослойными системами, где вакуумная изоляция и азотный экран должны работать синхронно. Проблема утечек и деградации вакуума является одной из критических в эксплуатации систем, поскольку высокая текучесть гелия усложняет поддержание герметичности, а деградация вакуума в изоляционном пространстве приводит к увеличению теплопритоков. Обозначенные проблемы ставят задачу разработки новых интеллектуальных подходов к управлению подобными системами – способных динамически адаптироваться к меняющимся внешним условиям и заблаговременно распознавать аномалии.

Итак, управление транспортными многослойными криогенными системами охватывает целый комплекс задач: минимизацию теплопритоков, точный контроль параметров среды, обеспечение надёжности материалов, предотвращение утечек.

Рассмотрение многослойной криогенной системы как объекта обработки информации выявляет её специфические черты: многопараметрическое описание состояния, нелинейное поведение (пороговый эффект при потере азотного экрана), жёсткие ограничения вычислительной платформы бортового контроллера, а также критические последствия ошибочных решений. Применяемый сегодня ручной процесс лишён формализованного анализа динамики параметров и вносит значительные временные задержки в цепочку принятия решений. Эти обстоятельства определяют актуальность и значимость исследований в области интеллектуальных методов обработки информации для криогенных систем, что требует предварительного анализа существующих подходов к решению подобных задач.

1.2 Анализ методов обработки информации и интеллектуального управления в криогенных технических системах

Основными задачами в области управления многослойными криогенными системами являются минимизация теплопередачи, разработка эффективных изоляционных материалов, внедрение интеллектуальных методов управления и мониторинга, а также повышение надежности и прогнозирование отказов. Теоретическую базу для анализа подобных объектов составляет общая теория систем, заложенная в трудах von Bertalanffy L. [118], и теория иерархических многоуровневых систем Mesarovic M.D. [96]. В отечественной науке математические задачи системного анализа развивались в работах Моисеева Н.Н. [43], а практические основы системного анализа технических объектов систематизированы Перегудовым Ф.И. и Тарасенко Ф.П. [48]. Применительно к сложным техническим системам с многоуровневой структурой, к которым относится транспортная многослойная криогенная система, методологические основы системного анализа развиты автором в работах [31; 32], где предложен фрактальный подход к оценке надёжности и эффективности технических систем с иерархической организацией. В рамках текущих научных исследований достигнут ряд значимых результатов, однако сохраняется необходимость дальнейшего анализа и совершенствования подходов, особенно в условиях экстремально низких температур и ограниченной доступности экспериментальных данных.

Научные исследования в области управления многослойными криогенными системами развиваются по нескольким взаимосвязанным направлениям. Первое направление связано с физическим моделированием криогенных процессов и разработкой моделей теплопроводности. Второе направление охватывает применение методов машинного обучения и интеллектуального анализа данных к задачам управления криогенным оборудованием. Третье направление посвящено формированию признаков пространств и обеспечению интерпретируемости моделей. Четвертое направление включает вопросы системного анализа, теории принятия решений и развертывания алгоритмов на встраиваемых платформах.

Систематизация основных направлений исследований, ключевых авторов, достигнутых результатов и выявленных ограничений представлена на Рисунке 1.3.



Рисунок 1.3 – Классификация методов обработки информации в криогенных системах

Теоретическими основами криогенной техники и физикой криогенных процессов занимались такие учёные, как Архаров А.М., Беляков В.П. и Микулин Е.И., чьи фундаментальные труды по теории низкотемпературных процессов заложили основу отечественной криогенной школы [7; 11]. Среди зарубежных фундаментальных источников по криогенной технике следует выделить работы Barron R.F. [62] и Flynn T.M. [74], систематизировавших инженерные основы проектирования и эксплуатации криогенных установок. В зарубежной литературе аналогичную роль сыграли работы Van Sciver S.W., посвященные физике жидкого гелия и термодинамическим свойствам криогенных сред при температурах вблизи абсолютного нуля [116]. Эти исследования сформировали теоретический фундамент для понимания процессов теплопереноса в многослойных криогенных конструкциях.

Проблематика минимизации теплопередачи в криогенных системах широко представлена как в отечественной, так и в зарубежной научной литературе. В России значительный вклад в моделирование теплофизических процессов внес Зарубин В.С. [37], занимавшийся расчетом параметров хранения и транспортировки криогенных продуктов. Его исследования привели к разработке моделей расчета теплопроводности многослойных изоляционных материалов, что позволило значительно повысить эффективность вакуумной теплоизоляции. Обработка экспериментальных данных, получаемых при испытаниях криогенных конструкций, опирается на методы прикладной статистики [6] и прикладного анализа данных [36]. Использование многослойных экранов, выполненных из алюминиевой фольги и стеклоткани, существенно снизило теплопритоки. Однако существующие модели, как правило, не учитывают влияние динамических факторов, таких как вибрации, термические расширения и микродеформации. Перечисленные аспекты нуждаются в дальнейшем теоретическом и экспериментальном изучении – без этого не построить более универсальных моделей теплопередачи, пригодных для условий эксплуатации при переменных нагрузках [37].

Моделированию процессов конвективного тепло- и массообмена в средах вблизи термодинамической критической точки посвящены работы Полежаева В.И. [47]. Обоснование системного подхода к разработке математических моделей технических процессов дано Бобковым С.П. и Астраханцевой И.А. [15]; методы имитационного моделирования на основе клеточных автоматов получили развитие в работах [12; 14] – эти подходы открывают путь к численному исследованию теплофизических процессов в криогенных конструкциях. По экспериментальным данным были изучены процессы неустойчивости потоков гелия и их влияние на теплопритоки. Выяснилось, что жидкий гелий при низких температурах проявляет высокую чувствительность к изменениям давления и тепловым воздействиям. Перечисленные исследования заложили основу, но используемые сегодня модели охватывают узкий круг физических явлений – преимущественно ламинарные

потоки, – а сложные турбулентные процессы, возникающие при транспортировке гелия, остаются вне поля зрения.

На теплопроводность критически влияют геометрические параметры изоляционных материалов: в первую очередь – толщина и конфигурация слоёв [7; 11]. Если их грамотно подобрать, теплопритоки удаётся заметно сократить, особенно в режимах длительной эксплуатации при низких температурах. Сказываются и внешние факторы: вибрации и температурные градиенты ускоряют деградацию материалов и снижают эффективность теплоизоляции. Чередование слоёв алюминиевой фольги и стекловолокнистой ткани ощутимо понижает коэффициент теплопроводности – особенно это важно при длительном хранении криогенных жидкостей [7].

Экспериментальные данные Woodcraft A.L. по теплопроводности алюминия различной чистоты в криогенном диапазоне температур [123] дают основание обоснованно подбирать материалы экранов с опорой на реальные условия эксплуатации. Оптимизация толщины каждого слоя не только улучшает изоляционные свойства, но и снижает массу всей системы, что приобретает критическое значение для аэрокосмических применений [116]. Зарубежные исследования, в том числе работы Daigle M.J. и Goebel K. [71], также посвящены разработке эффективных моделей управления тепловыми потоками при сверхнизких температурах.

Современные исследования материалов для криогенных систем ориентированы на создание эффективных изоляционных структур, устойчивых к экстремальным температурным и механическим воздействиям. Возникающие под воздействием вибраций микродеформации заметно повышают теплопроводность изоляционных материалов – проблема становится особенно острой в криогенных условиях [47]. Применение аэрогелей даёт снижение теплопередачи до 30 процентов по сравнению с традиционными материалами и одновременно уменьшает массу конструкции; как перспективный элемент многослойной изоляции они описаны в [116]. Вместе с тем, несмотря на перспективность указанных материалов, долговечность их структуры при циклических термических

и механических воздействиях изучена недостаточно. В итоге детерминированные модели теплофизических процессов, составляющие основу данного направления, не принимают во внимание стохастичность реальных условий эксплуатации транспортных криогенных систем.

Применение методов машинного обучения и интеллектуального анализа данных к криогенным техническим системам представляет второе направление исследований. Теоретический фундамент данного направления составляют работы по восстановлению зависимостей по эмпирическим данным [17], теории статистического обучения [61; 64; 79; 99] и теории распознавания образов [57]. Общий обзор состояния и перспектив машинного обучения представлен в работе Jordan M.I. и Mitchell T.M. [87], а современные подходы к искусственному интеллекту систематизированы Russell S. и Norvig P. [108]. В отечественной литературе методы искусственного интеллекта изложены в трудах Осипова Г.С. [46], проблемы и перспективы интеллектуальных систем управления проанализированы Захаровым В.Н. [38], а основы теории систем и системного анализа в приложении к управлению рассмотрены Качалой В.В. [39]. Pezzetti M. исследовал управление крупными гелиевыми криогенными системами на примере Большого адронного коллайдера, продемонстрировав возможность автоматизированного выявления отклонений от нормального режима работы сложного криогенного оборудования [103]. Saha B. и Goebel K. разработали подходы к прогностике состояния оборудования на основе байесовского вывода, показав высокую точность прогнозирования отказов при наличии достаточного объема обучающих данных [109]. Среди классических методов обучения с учителем, пригодных для работы на ограниченных выборках, особое место занимают метод опорных векторов [70], деревья решений [105], метод случайных лесов [65] и ансамблевые методы в целом [72]. Алгоритмы градиентного бустинга, включая стохастический градиентный бустинг [76], реализации XGBoost [68], LightGBM [90] и CatBoost [104], продемонстрировали высокую эффективность в задачах классификации и регрессии на структурированных данных. Теория принятия решений, формализующая процедуры выбора в условиях

неопределенности, рассмотрена в работах Ларичева О.И. [42], а сравнительный анализ алгоритмов обучения с учителем выполнен Caruana R. и Niculescu-Mizil A. [67]. Heng A. и соавторы систематизировали методы прогностики вращающегося оборудования с применением методов машинного обучения, подтвердив эффективность подхода для снижения внеплановых простоев оборудования [81]. Gebraeel N. с соавторами разработал нейросетевой подход к оценке остаточного ресурса по сигналам вибрационной деградации [77].

Методы динамического управления с применением искусственного интеллекта, опирающиеся на непрерывную переоценку параметров системы по изменению температуры, давления и вибрации, описаны в работах Daigle M. (NASA) и Pezzetti M. (CERN). В их основе – алгоритмы адаптивного управления с обратной связью; при отклонениях от заданных параметров управляющие воздействия корректируются автоматически. Такие программы решают сразу две задачи: поддерживают механическую целостность системы и выявляют потенциальные аварийные ситуации – утечки, перегревы, разрывы компонентов [4; 71; 86]. Прогнозирование отказов является ключевым элементом повышения надежности криогенных систем. Подходы Daigle M.J. и Goebel K. [71], основанные на машинном обучении, доказали свою эффективность, позволяя снизить вероятность внеплановых простоев на 25 процентов. В отечественной научной традиции также уделяется внимание разработке стандартов для интеллектуальных систем диагностики криогенных систем, однако наиболее детально эти идеи реализованы в зарубежных проектах ISHM (NASA) и системах мониторинга Большого адронного коллайдера (CERN).

В последние годы заметно усилился интерес к применению распределённых сенсорных сетей и методов машинного обучения для постоянного мониторинга параметров состояния криогенных систем. Сетевые сенсоры, объединённые в распределённую систему, передают данные в интеллектуальные управляющие модули в режиме реального времени; встроенные в эти модули алгоритмы анализа временных рядов выявляют отклонения от штатного режима работы. За счёт подобного подхода удаётся прогнозировать развитие критических ситуаций –

утечки гелия, деградацию изоляции, снижение эффективности охлаждения [71; 94; 113]. На потенциал математического моделирования в инженерных задачах указывают работы Свиридюка Г.А. [53], а экспериментальные исследования Pezzetti М. [103] подтверждают возможность практической реализации интеллектуальных технологий на действующих криогенных системах. Глубокие нейронные сети, теоретические основы которых изложены в работах Гудфеллоу И.Г. [34], Хайкина С. [58] и Bengio Y. [63], активно применяются для решения сложных задач прогностики и управления [78; 93]. Среди архитектур нейронных сетей особую роль играют сети долгой краткосрочной памяти [83], механизм внимания и архитектура трансформеров [117], а также методы снижения размерности с помощью автокодировщиков [82]. Искусственные нейронные сети в приложении к инженерным задачам рассмотрены Кругловым В.В. [41], нейронные сети, генетические алгоритмы и нечеткие системы систематизированы Рутковской Д. [52]. Методы глубокого обучения с подкреплением, в том числе обучение управлению на уровне человеческих возможностей [97] и алгоритм Q-обучения [121], открывают перспективы адаптивного управления техническими системами, однако такие подходы требуют значительных вычислительных мощностей в виде графических ускорителей, что делает их неприменимыми для бортовых контроллеров транспортных криогенных систем. Таким образом, предложенные в рамках данного направления методы ориентированы преимущественно на стационарные установки с доступом к значительным вычислительным ресурсам.

Третье направление исследований связано с формированием информативных признаков пространств и обеспечением интерпретируемости моделей машинного обучения. Автоматизация формирования признаков пространств развивается в рамках направления автоматизированного машинного обучения. Методы автоматической генерации признаков, включая глубокий синтез признаков [88] и извлечение признаков из временных рядов [69], позволяют систематизировать процесс формирования информативных представлений данных. Библиотеки автоматического конструирования признаков [84] и платформы автоматизированного машинного обучения [73; 80; 85] упрощают процесс

построения моделей, однако их применение предполагает наличие значительных объемов данных и вычислительных ресурсов. Инженерия признаков как самостоятельная дисциплина систематизирована в работе Zheng A. и Casari A. [124]. Теорема Wolpert D.H. о невозможности универсального алгоритма оптимизации [122] обосновывает необходимость учёта специфики предметной области при выборе методов. Подходы к интеграции физических знаний в модели машинного обучения развивались в работах Raissi M. и Karniadakis G.E., предложивших концепцию физически обоснованных нейронных сетей, в которых уравнения физики используются как регуляризирующие ограничения при обучении [89; 106]. Данный подход позволяет повысить точность моделей при ограниченном объеме обучающих данных за счёт привлечения априорных знаний о физике процессов. Вместе с тем реализация физически обоснованных сетей сопряжена со значительными вычислительными затратами, которые несовместимы с ограничениями встраиваемых контроллеров.

Проблематика интерпретируемости моделей машинного обучения получила развитие в работах Lundberg S.M. и Lee S.-I.: авторами предложен метод аддитивной декомпозиции на основе значений Шепли, с помощью которого объясняются предсказания произвольных моделей [95]. Ribeiro M.T. с соавторами разработали метод локальной интерпретируемости – в нём поведение сложной модели в окрестности конкретного наблюдения аппроксимируется простой линейной моделью [107]. Методы такого рода делают процесс принятия решений прозрачным, что приобретает особое значение в системах критического применения: оператор должен понимать, на каких основаниях сформирована рекомендация. Систематизированное изложение подходов к интерпретируемости моделей машинного обучения дано в монографии Molnar C. [98]. Методы трансферного обучения [101] позволяют переносить знания между предметными областями, но их применимость к криогенным системам ограничена – в этой области отсутствуют крупные открытые наборы данных. Подходы к оценке точности моделей методами перекрестной проверки и бутстрэпа систематизированы Kohavi R. [92], а метод стохастической оптимизации Adam [91]

стал стандартным инструментом обучения нейронных сетей. Вычислительная эффективность глубоких нейронных сетей исследована Sze V. [115], а метрики оценки прогностических моделей систематизированы Saxena A. [110]. Вместе с тем большинство существующих алгоритмов машинного обучения, включая случайные леса, градиентный бустинг и многослойные нейронные сети, не адаптированы к работе с ограниченными, зашумленными или неполными наборами данных, характерными для криогенных систем. Низкая частота сбора данных, ограниченная точность и прецизионность измерений [1], высокая чувствительность измерительных цепей к электромагнитным и температурным помехам, а также высокая вариативность условий эксплуатации требуют внедрения предварительной фильтрации и валидации достоверности данных. Методы анализа данных, включая технологии интеллектуального анализа данных и оперативной аналитической обработки [10], а также дифференцируемый отбор признаков с помощью автокодировщиков [60], могут повысить качество предобработки, однако их адаптация к специфике криогенных измерений не исследована. Таким образом, алгоритмы формализации физических соотношений в оператор преобразования признаков, пригодные для использования на встраиваемых системах с ограниченными ресурсами, в настоящее время не разработаны.

Четвертое направление охватывает вопросы системного анализа, теории принятия решений и развертывания моделей машинного обучения на платформах с ограниченными вычислительными ресурсами. Математическая теория информации, заложенная в работах Shannon C.E. [112] и получившая развитие в исследованиях Колмогорова А.Н. о подходах к определению количества информации [40], и статистическая теория принятия решений, развитая в трудах Wald A. [119], составляют теоретический фундамент для формализации процессов обработки информации в технических системах. В отечественной науке вопросы теории информационных процессов и систем исследовались Советовым Б.Я. [54], вопросы управления сложными информационными системами развивались в работах Юсупова Р.М. [59]. Экспертные системы для решения неформализованных задач были предложены Поповым Э.В. [49], теория ситуационного управления

разработана Пospelовым Д.А. [50], а методы адаптации сложных систем исследованы Растригиным Л.А. [51]. Проблематика многоагентных систем, актуальная для распределенного управления техническими объектами, развивалась в работах Городецкого В.И. [33] и Тарасова В.Б. [55]. Базы знаний интеллектуальных систем систематизированы Гавриловой Т.А. и Хорошевским В.Ф. [19]. Вопросы управления в социальных и экономических системах рассмотрены Бурковым В.Н. и Новиковым Д.А. [16], а современные тенденции на стыке искусственного интеллекта и теории принятия решений проанализированы Тимохиным М.Ю. и Шараниным В.Ю. [56]. Теория принятия решений и управления разрабатывалась Новиковым Д.А. [45]. Проблемы системного анализа и управления в контексте технических объектов рассматривались в работах Монахова М.Ю., Жизняка А.Л., Астраханцевой И.А. и Бобкова С.П. [8; 13; 44].

Развертыванием моделей машинного обучения на встраиваемых системах с ограниченными вычислительными ресурсами занимались Warden P. и Situnayake D., систематизировавшие подходы к малоресурсному обучению и инференсу на микроконтроллерах [120]. Эффективное управление криогенными системами требует комплексного подхода, включающего автоматизацию процессов мониторинга и контроля. Применение интеллектуальных датчиков температуры и давления позволяет в реальном времени отслеживать состояние системы [103]. Эволюционные методы моделирования и оптимизации [35] и поиск архитектуры нейронных сетей с помощью обучения с подкреплением предлагают альтернативные подходы к автоматизации проектирования моделей, однако их вычислительная стоимость несовместима с ограничениями бортовых систем. Дополнительную сложность представляет интеграция интеллектуальных алгоритмов с существующими промышленными платформами управления на основе программируемых логических контроллеров и систем диспетчерского управления, изначально не рассчитанными на высокоуровневую аналитику. Проблемы скрытого технического долга при внедрении систем машинного обучения в промышленную эксплуатацию проанализированы Sculley D. [111], а библиотека `scikit-learn` [102] стала стандартным инструментом для

прототипирования и развертывания классических моделей машинного обучения. Обучение с подкреплением [114] открывает возможности для адаптивного управления, однако требует значительного объема взаимодействий с средой, что затруднено для криогенных систем. Открытым остаётся вопрос о физической интерпретируемости моделей искусственного интеллекта. В криогенной технике это принципиально: управляющее решение должно быть обосновано с учётом термодинамических и конструкционных ограничений. Моделей, охватывающих полный цикл обработки информации – от сбора данных до управленческого решения с механизмом адаптации на эксплуатационных данных, – на сегодняшний день нет.

Если обобщить, в области управления многослойными криогенными системами достигнут заметный прогресс. Развитие материаловедения позволило получить высокоэффективные теплоизоляционные решения, сводящие теплопритоки к минимуму и улучшающие энергетику систем. Параллельно разработаны и проверены интеллектуальные алгоритмы для управления параметрами таких систем – с прогнозированием отказов и оптимизацией энергопотребления. Внедрены сенсорные и сетевые технологии, обеспечивающие мониторинг и диагностику оборудования в реальном времени. Вместе с тем проведенный анализ по четырём направлениям выявил ряд ограничений существующих подходов, совокупность которых определяет необходимость систематизации требований к методам решения задачи и формализации научной задачи исследования.

1.3 Обоснование требований к методам решения задачи и постановка научной задачи исследования

Проведенный анализ современных методов обработки информации и интеллектуального управления в криогенных технических системах позволяет систематизировать выявленные ограничения и определить направления, требующие научной проработки. Несмотря на значительный прогресс в области

физического моделирования, машинного обучения, формирования признаков пространств и системного анализа, существующие подходы обладают фундаментальными ограничениями, препятствующими их прямому применению к задаче интеллектуального управления транспортной многослойной криогенной системой.

Рассматриваемая транспортная многослойная криогенная система предназначена для перевозки жидкого гелия и включает вакуумную изоляцию и азотный экран. Практическая задача управления состоит в следующем. На основании текущих показаний датчиков необходимо определить, требуется ли в данный момент времени выполнить долив жидкого азота в защитный контур. Исходными данными для принятия решения служат показания измерительной системы, включающие уровень и давление жидкого гелия, уровень и давление жидкого азота, а также статус контейнера, отражающий режим эксплуатации. Задача носит бинарный характер и предполагает формирование рекомендации «требуется долив» или «долив не требуется».

Жидкий азот в защитном контуре выполняет функцию охладителя, снижающего теплоприток к гелиевому резервуару. По мере испарения азота эффективность теплозащиты снижается, что приводит к росту давления гелия и увеличению его потерь. Своевременный долив азота позволяет поддерживать стабильный температурный режим и минимизировать экономические потери, связанные с высокой стоимостью жидкого гелия. Запаздывание в принятии решения приводит к потерям дорогостоящего продукта, тогда как избыточно частый долив увеличивает эксплуатационные расходы.

Классический подход к решению подобных задач предполагает построение аналитической модели, описывающей зависимость давления гелия от совокупности измеряемых параметров. Такая модель должна учитывать термодинамические процессы теплопереноса через многослойную изоляцию, фазовые переходы криогенных жидкостей, влияние внешних условий и динамических нагрузок при транспортировке. Однако вывод аналитической зависимости сопряжен с принципиальными трудностями.

Сложность физических процессов в многослойной криогенной системе обусловлена взаимосвязанностью явлений теплопроводности, конвекции и излучения в условиях глубокого вакуума и криогенных температур. Нелинейный характер зависимостей, наличие фазовых переходов и влияние конструктивных особенностей изоляции делают построение точной аналитической модели чрезвычайно трудоемким. Кроме того, данные измерительной системы содержат значительный уровень шума, обусловленный погрешностями датчиков, вибрационными воздействиями при транспортировке и кратковременными сбоями измерительных каналов. Применение аналитических моделей к зашумленным данным приводит к существенным погрешностям прогнозирования. Детерминированные модели теплофизических процессов не учитывают стохастичность реальных условий эксплуатации транспортных криогенных систем.

В качестве альтернативы аналитическому моделированию предлагается рассматривать задачу определения необходимости управляющего воздействия как задачу аппроксимации неизвестной зависимости по эмпирическим данным. Такая постановка позволяет использовать методы машинного обучения для построения классификатора, отображающего вектор измеряемых параметров в бинарную рекомендацию. Вероятностная природа методов машинного обучения обеспечивает устойчивость к шуму в исходных данных и позволяет учитывать сложные нелинейные зависимости без явного моделирования физических процессов.

Однако применение методов машинного обучения к рассматриваемой задаче сопряжено с рядом существенных ограничений, обусловленных спецификой предметной области и условиями эксплуатации.

Первое ограничение связано с объемом доступных данных. Накопление исторических данных о состоянии криогенных систем происходит медленно вследствие длительности транспортных циклов и относительной редкости событий, требующих управляющего воздействия. Объем обучающей выборки существенно ограничен и недостаточен для эффективного обучения глубоких

нейронных сетей, требующих выборок на порядки большего размера. Применение методов автоматизированного построения моделей также ограничено малым объемом данных, поскольку эти методы предполагают выделение значительной части выборки для валидации множества конкурирующих конфигураций.

Второе ограничение обусловлено вычислительными возможностями целевой платформы. Система поддержки принятия решений должна функционировать непосредственно на борту транспортного средства, поскольку в процессе перевозки доступ к внешним вычислительным ресурсам может отсутствовать. Бортовые контроллеры транспортных криогенных систем построены на микроконтроллерах с ограниченными ресурсами, не предполагающих использования графических ускорителей. Объем оперативной памяти типового контроллера не превышает нескольких сотен килобайт. Это исключает применение ресурсоемких методов машинного обучения, таких как глубокие нейронные сети и ансамбли большой размерности.

Третье ограничение связано с требованием автономности функционирования. В процессе транспортировки автомобильным или железнодорожным транспортом доступ к сети передачи данных может отсутствовать на протяжении значительных интервалов времени. Система поддержки принятия решений должна функционировать полностью автономно, без обращения к облачным сервисам или удаленным серверам. Это исключает использование распределенных вычислительных архитектур и моделей, требующих постоянного обновления параметров.

Четвертое ограничение обусловлено требованием интерпретируемости решений. Окончательное решение о выполнении управляющего воздействия принимает оператор криогенной системы. Для обоснованного принятия решения оператор должен понимать, какие параметры системы привели к формированию той или иной рекомендации. Модели типа «черного ящика», не обеспечивающие объяснения своих решений, вызывают недоверие у эксплуатирующего персонала и препятствуют внедрению интеллектуальных систем в промышленную практику.

Пятое ограничение связано с существенным дисбалансом классов в обучающей выборке. Необходимость долива азота возникает относительно редко, поскольку жидкий азот испаряется постепенно. Мажоритарный класс, соответствующий состоянию «долив не требуется», многократно превышает миноритарный. При этом цена ошибок различных типов существенно различается. Пропуск события, требующего долива, приводит к оголению азотного экрана, резкому увеличению теплопритока и потерям жидкого гелия стоимостью десятки тысяч долларов. Ложное срабатывание ограничивается временными затратами оператора на проверку системы. Такая асимметрия последствий ошибок определяет приоритет полноты обнаружения критических событий над общей точностью классификации.

Систематизация ограничений существующих подходов и требований к методам решения представлена в Таблице 1.3.

Таблица 1.3 – Требования к методам решения задачи

Требование	Источник ограничения	Следствие для выбора метода
Работоспособность на малых выборках	Длительность транспортных циклов, редкость критических событий	Исключены глубокие нейронные сети и методы автоматизированного построения моделей
Малый объем вычислительных ресурсов	Бортовой микроконтроллер с ограниченной памятью	Исключены ансамбли большой размерности и модели, требующие графических ускорителей
Автономность функционирования	Отсутствие связи при транспортировке	Исключены облачные сервисы и распределенные архитектуры
Интерпретируемость решений	Оператор принимает окончательное решение	Исключены модели типа «черного ящика» без механизма объяснения
Устойчивость к дисбалансу классов	Редкость событий, требующих управляющего воздействия	Необходимы специальные методы работы с несбалансированными данными
Асимметрия ошибок	Высокая стоимость пропуска критического события	Приоритет полноты обнаружения над общей точностью

Перечисленные ограничения определяют требования к методам машинного обучения, применимым для решения рассматриваемой задачи. Архитектурное

описание разрабатываемой системы должно соответствовать принципам, сформулированным в международном стандарте описания архитектуры систем [3]. Необходимы классические методы обучения с учителем, обеспечивающие высокую точность классификации при обучении на выборках ограниченного объема, функционирующие в условиях жестких ограничений на вычислительные ресурсы и обеспечивающие интерпретируемость принимаемых решений.

Помимо перечисленных практических ограничений проведенный анализ позволил выявить нерешённые научные задачи, непосредственно определяющие содержание диссертационного исследования. В предшествующих публикациях автором развит фрактальный подход к анализу сложных технических систем с многоуровневой организацией [31; 32], применимый к описанию иерархической структуры МКС, и предложены математические модели оптимизации с регуляторными ограничениями [23], методологические принципы которых использованы при формализации вектора ограничений Ψ в настоящей работе. Указанные результаты послужили методологической основой диссертационного исследования и в нём получили дальнейшее развитие применительно к задаче интеллектуального управления многослойной криогенной системой. Каждая из этих задач порождена конкретным пробелом в существующем научном аппарате, а их совместное решение необходимо для создания полноценной системы интеллектуальной поддержки управления многослойной криогенной системой.

Первая нерешенная задача состоит в отсутствии формализованного метода формирования признакового пространства с учётом физики процессов теплопереноса для встраиваемых систем с ограниченными ресурсами. Существующие методы автоматической генерации признаков не учитывают термодинамические закономерности функционирования криогенных систем. Взаимосвязь между уровнем и давлением криогенных сред, обусловленная уравнениями состояния, не используется при построении моделей. Методы экспертного конструирования признаков описаны в литературе фрагментарно и не имеют формализованного регламента, обеспечивающего воспроизводимость результатов. Необходим систематический подход к формированию признакового

пространства, интегрирующий экспертное знание о физике процессов и обеспечивающий работоспособность в условиях ограниченных вычислительных ресурсов. Задача обладает двумя существенными особенностями. Первая связана с тем, что преобразование признаков должно быть вычислительно реализуемо на встраиваемом контроллере с ограниченной памятью. Вторая определяется необходимостью количественной валидации вклада сконструированных признаков в качество классификации.

Вторая нерешенная задача заключается в отсутствии алгоритмов представления результатов классификации, обеспечивающих интерпретируемость и переход к верифицируемому управленческому решению оператора в условиях ограничений бортового контроллера. Традиционные методы автоматического регулирования формируют управляющее воздействие непосредственно, без участия оператора. Однако в условиях неполных данных и высокой стоимости ошибок более надежным является подход, при котором система формирует рекомендацию, а окончательное решение принимает оператор. Проблема обеспечения прозрачности принимаемых решений приобретает особую остроту для систем критического применения, где оператор должен понимать, какие параметры системы привели к формированию рекомендации о необходимости управляющего воздействия. Методы объяснимого искусственного интеллекта способны визуализировать вклад каждого признака в решение модели, однако их адаптация к специфике криогенных систем с учётом ограничений встраиваемых платформ требует дополнительных исследований. Задача включает два взаимосвязанных аспекта. Первый состоит в разработке модели классификации состояний, работающей в условиях ограниченных ресурсов. Второй связан с обеспечением такого представления результатов, которое позволяет оператору обоснованно принимать или отклонять сформированную рекомендацию.

Третья нерешенная задача состоит в отсутствии моделей системы поддержки принятия решений, формализующих полный цикл обработки информации от сбора данных до формирования управленческого решения с механизмом адаптации на эксплуатационных данных. Промышленные системы управления построены на

базе программируемых логических контроллеров и систем диспетчерского управления, изначально не рассчитанных на интеграцию с интеллектуальными алгоритмами. Дополнительную сложность представляет необходимость обеспечения адаптации модели по мере накопления эксплуатационных данных без полного переобучения, требующего значительных вычислительных ресурсов. Вопросы выбора варианта размещения модели, протоколов обмена данными и процедур валидации решений на встраиваемых платформах требуют систематического исследования. Задача обладает тремя существенными особенностями. Первая связана с необходимостью формализации технологического процесса обработки информации как целостной последовательности этапов. Вторая определяется требованием интеграции интеллектуальных алгоритмов с существующими промышленными платформами управления. Третья обусловлена необходимостью механизма адаптации, позволяющего системе улучшать качество работы по мере накопления эксплуатационных данных.

Перечисленные нерешенные задачи взаимосвязаны и образуют единый комплекс. Формирование признакового пространства на основе физических соотношений задает основу, на которой строится алгоритм классификации состояний. Алгоритм представления результатов обеспечивает переход от машинного прогноза к верифицируемому решению оператора. Функциональная модель системы поддержки принятия решений объединяет все этапы обработки информации в замкнутый цикл с механизмом адаптации. Взаимосвязь нерешённых научных задач представлена на Рисунке 1.4.




Рисунок 1.4 – Взаимосвязь нерешённых научных задач диссертационного исследования

Решение перечисленных задач нуждается в экспериментальном подтверждении на реальных данных сенсорных систем криогенных контейнеров. Для этого необходима программная реализация предложенных моделей и алгоритмов, а также проведение серии экспериментальных исследований с количественной оценкой результатов, включая сравнение с существующим подходом на основе ручного контроля.

Выявленные задачи определяют потребность в разработке моделей и алгоритмов интеллектуального управления многослойной криогенной системой, обеспечивающих повышение качества и оперативности обработки информации за счёт многокритериальной оптимизации с ограничениями. Такая система должна опираться на формализованный метод формирования признакового пространства на основе физики процессов, включать алгоритм интеллектуальной поддержки принятия решений с обеспечением интерпретируемости для оператора, формализовать технологический процесс обработки информации от сбора данных до формирования управленческого решения и быть верифицирована на реальных данных сенсорных систем криогенных контейнеров. Физико-математическая постановка задачи и обоснование выбора конкретных методов составляют предмет следующей главы диссертационного исследования.

Выводы по главе 1

В первой главе выполнен анализ методов и алгоритмов обработки информации в системах управления криогенными техническими объектами.

1. Исследована многослойная криогенная система как объект управления и обработки информации. Рассмотрена физическая структура системы, включающая гелиевый резервуар при температуре 4,2 К, азотный экран при 77 К и вакуумную теплоизоляцию. Описан пороговый эффект потери экранирующего слоя, приводящий к увеличению теплопритока в 250 раз. Идентифицированы четыре функциональных блока технологического процесса обработки информации и определены пять контролируемых параметров сенсорной подсистемы. Показано, что существующий процесс управления основан на неформализованной визуальной оценке, не учитывает совместную динамику параметров и существенно зависит от опыта оператора.

2. Проведен анализ методов обработки информации по четырем направлениям (физическое моделирование, машинное обучение, формирование признаков и интерпретируемость, системный анализ и развертывание), выполнено сопоставление по критериям вычислительной сложности, интерпретируемости, требований к объему данных и совместимости с ограничениями встраиваемых платформ. Выявлено, что каждое направление покрывает лишь часть указанных критериев. Детерминированные физические модели не учитывают стохастичность реальных условий, методы глубокого обучения требуют вычислительных ресурсов, несовместимых с бортовыми контроллерами, алгоритмы формализации физических соотношений в оператор преобразования признаков для встраиваемых систем не разработаны, а модели полного цикла обработки информации с механизмом адаптации отсутствуют.

3. Сформулирована задача интеллектуальной поддержки управления как задача бинарной классификации состояний многослойной криогенной системы. Показано, что классический подход на основе аналитического моделирования

сопряжен с принципиальными трудностями вследствие взаимосвязанности явлений теплопроводности, конвекции и излучения в условиях глубокого вакуума и криогенных температур. Обоснована целесообразность применения методов машинного обучения для аппроксимации неизвестной зависимости по эмпирическим данным, обеспечивающих устойчивость к шуму без явного моделирования физических процессов.

4. Систематизированы ограничения, определяющие специфику решаемой задачи, и сформулированы требования к методам решения. Ограниченный объем обучающей выборки исключает применение глубоких нейронных сетей. Вычислительные возможности бортового контроллера и требование автономной работы исключают использование ресурсоемких методов и облачных сервисов. Дисбаланс классов и асимметрия последствий ошибок требуют специальных методов работы с несбалансированными данными. Требование интерпретируемости обусловлено тем, что окончательное решение принимает оператор.

5. На основании проведенного анализа выявлен комплекс нерешённых научных задач, составляющих предмет диссертационного исследования. Формирование признакового пространства на основе физических соотношений задает основу для алгоритма классификации, алгоритм представления результатов обеспечивает переход от машинного прогноза к верифицируемому решению оператора, а функциональная модель системы объединяет все этапы в замкнутый цикл с механизмом адаптации на эксплуатационных данных. Их решение составляет научную основу для создания системы интеллектуальной поддержки управления многослойной криогенной системой.

Результаты получены автором лично и были частично опубликованы в соавторстве в [21; 23; 24; 27; 28; 29; 32].

2 Физико-математическая постановка задачи обработки информации в системе управления многослойной криогенной системой

2.1 Анализ применимости детерминированного подхода к задаче определения состояния экранирующего слоя

Исследуемая многослойная криогенная система (МКС) представляет собой транспортный резервуар для перевозки и длительного хранения жидкого гелия, конструкция и основные технические характеристики которой описаны в первой главе. Для формализации задачи управления и построения математической модели поддержки принятия решений необходимо определить МКС как объект управления в терминах системного анализа. МКС формально определяется кортежем (2.1).

$$MKS = \langle R_{He}, R_{N_2}, V, A \rangle, \quad (2.1)$$

где R_{He} – гелиевый контур – внутренний сосуд с жидким гелием при температуре 4,2 К, эксплуатационном давлении 0,05–0,15 МПа (расчётное предельное давление – 0,6 МПа согласно Таблице 1.1) и номинальном объёме 40 м³; назначение контура – хранение и транспортировка криогенного продукта;

R_{N_2} – азотный экран – промежуточная полость с жидким азотом при температуре 77 К; выполняет функцию радиационного теплового щита и перехватывает до 99,6 % теплового излучения, идущего от внешней оболочки;

V – вакуумная полость с многослойной экранно-вакуумной изоляцией (МЭВИ) при остаточном давлении 10^{-4} – 10^{-6} Па; за счёт неё минимизируется газовая теплопроводность;

A – бортовая система автоматики, включающая контроллер серии STM32 с оперативной памятью 256 КБ и тактовой частотой 168 МГц, обеспечивающий сбор данных, формирование управляющих воздействий и взаимодействие с оператором.

Ключевым эксплуатационным параметром МКС является суточная норма потерь криогенного продукта на испарение, которая для современных цистерн составляет не более 0,3–0,5 % от объема в сутки. Превышение данного показателя свидетельствует о нарушении теплоизоляции и требует проведения диагностики. Суточные потери определяются суммарным теплопритоком к внутреннему сосуду, который складывается из трёх основных составляющих (2.2).

$$Q_{total} = Q_{rad} + Q_{cond} + Q_{gas}, \quad (2.2)$$

где Q_{total} – суммарный теплоприток к гелиевому контуру, Вт;

Q_{rad} – радиационный теплоприток от теплового излучения окружающих поверхностей, Вт;

Q_{cond} – кондуктивный теплоприток через элементы механической подвески внутреннего сосуда, Вт;

Q_{gas} – теплоприток за счёт остаточной газовой теплопроводности в вакуумной полости, Вт.

При исправной изоляции доминирующей составляющей является радиационный теплоприток Q_{rad} , на долю которого приходится до 80 % суммарного теплопритока. Оставшиеся 20 % распределяются между кондуктивной и газовой составляющими.

Радиационный теплоприток определяется законом Стефана–Больцмана. Для системы концентрических оболочек с различными температурами он описывается выражением (2.3).

$$Q_{rad} = \sigma \cdot \varepsilon_{eff} \cdot A \cdot (T_1^4 - T_2^4), \quad (2.3)$$

где $\sigma = 5,67 \cdot 10^{-8}$ Вт/(м² · К⁴) – постоянная Стефана–Больцмана;

ε_{eff} – эффективная степень черноты системы экранов, безразмерная величина;

A – площадь теплообменной поверхности, м²;

T_1 – температура горячей поверхности (внешняя оболочка или азотный экран), К;

T_2 – температура холодной поверхности (гелиевый контур), К.

Эффективная степень черноты ε_{eff} учитывает геометрию концентрических цилиндрических поверхностей и определяется соотношением (2.4).

$$\varepsilon_{eff} = \frac{1}{\frac{1}{\varepsilon_1} + \frac{A_1}{A_2} \left(\frac{1}{\varepsilon_2} - 1 \right)}, \quad (2.4)$$

где $\varepsilon_1, \varepsilon_2$ – степени черноты внутренней и внешней поверхностей соответственно;

A_1, A_2 – площади этих поверхностей.

Для системы с многослойной экранно-вакуумной изоляцией из n экранов эффективная степень черноты определяется как ε_{eff} / n , где ε_{eff} задано соотношением (2.4) для пары смежных поверхностей, и составляет порядка 10–3–10–2 при $n = 40$.

Назначение азотного экрана R_{N_2} – перехватывать тепловое излучение от внешней оболочки, нагретой примерно до 300 К. С экраном при 77 К радиационный теплоприток к гелиевому контуру падает в соотношении (2.5).

$$\frac{Q_{rad}^{(экp)}}{Q_{rad}^{(без)}} = \frac{77^4 - 4,2^4}{300^4 - 4,2^4} \approx 0,004. \quad (2.5)$$

То есть с азотным экраном радиационный теплоприток падает примерно в 250 раз. Отсюда и критическая важность контроля уровня жидкого азота – без него штатный режим МКС не удержать. Когда уровень опускается ниже критического порога δ ($L_{N_2} < \delta$, где $\delta \approx 10\text{--}15\%$ от номинального объёма), верхняя часть азотного экрана оголяется. Ничем не охлаждаемая, она быстро прогревается до температуры окружающей среды, и радиационный теплоприток к гелиевому контуру локально подскакивает. Эффект нелинейный и пороговый: при достижении критического уровня азота теплоприток растёт скачкообразно.

Пороговый характер этого явления существенен для построения математической модели, поскольку линейные методы не способны адекватно описать подобную зависимость без введения специальных признаков.

Кондуктивный теплоприток обусловлен теплопроводностью элементов механической подвески внутреннего сосуда, к которым относятся стяжки, опоры, трубопроводы заправки и слива, предохранительные клапаны. Кондуктивный теплоприток описывается выражением (2.6).

$$Q_{cond} = \sum_i \frac{\lambda_i \cdot A_i}{L_i} \cdot (T_{hot} - T_{cold}), \quad (2.6)$$

где λ_i – коэффициент теплопроводности i -го элемента, Вт/(м·К);

A_i – площадь поперечного сечения i -го элемента, м²;

L_i – длина теплопроводящего пути i -го элемента, м;

T_{hot} – температура горячего конца элемента, К;

T_{cold} – температура холодного конца элемента, К.

Коэффициент теплопроводности λ_i в формуле (2.6) представляет собой интегральную среднюю величину в температурном диапазоне $T_{cold} \dots T_{hot}$, вычисляемую как (2.7).

$$\lambda_{avg} = \frac{1}{T_{hot} - T_{cold}} \int_{T_{cold}}^{T_{hot}} \lambda(T) dT. \quad (2.7)$$

Для инженерных расчетов допускается использование табличных значений λ при средней температуре $(T_{hot} + T_{cold})/2$. Возникающая систематическая относительная погрешность не превышает 15–20 % и является приемлемой для качественной оценки вклада кондуктивной составляющей в суммарный теплоприток. Минимизация кондуктивного теплопритока достигается применением конструкционных материалов с низкой теплопроводностью (стеклопластик, нержавеющая сталь) и увеличением длины теплопроводящего пути за счёт использования тонкостенных трубок и гофрированных элементов.

Остаточная газовая теплопроводность определяется молекулярным режимом теплопереноса в разреженном газе при давлениях $P < 10^{-1}$ Па. В молекулярном режиме длина свободного пробега молекул превышает характерный размер зазора между поверхностями, и теплоперенос осуществляется за счёт прямого переноса энергии молекулами от горячей поверхности к холодной (2.8).

$$Q_{gas} = \alpha \cdot A \cdot P \cdot \frac{T_1 - T_2}{\sqrt{T_m}}, \quad (2.8)$$

где α – сводный коэффициент теплопередачи в молекулярном режиме, включающий коэффициент аккомодации α_a (типичные значения 0,3–0,9), показатель адиабаты γ , молярную массу газа M_{mol} и универсальную газовую постоянную R , характеризующий эффективность обмена энергией между молекулой газа и поверхностью, безразмерная величина;

A – площадь теплообменной поверхности, m^2 ;

P – остаточное давление в вакуумной полости, Па;

T_1, T_2 – температуры горячей и холодной поверхностей соответственно, К;

T_m – средняя температура газа, К.

Соотношение (2.8) справедливо в молекулярном (кнудсеновском) режиме теплопереноса, реализующемся при числе Кнудсена $Kn = l/d > 1$, где l – длина свободного пробега молекул, d – характерный размер зазора. Для азота при температуре 300 К данное условие выполняется при давлениях $P < 10^{-1}$ Па. В штатном режиме эксплуатации МКС давление в вакуумной полости V поддерживается на уровне 10^{-3} – 10^{-2} Па, что гарантирует применимость молекулярной модели. При ухудшении вакуума (натекание через микротрещины, дегазация материалов МЭВИ) значение Q_{gas} возрастает пропорционально давлению, что приводит к увеличению суммарного теплопритока и повышенным потерям криогенного продукта.

Бортовая система мониторинга МКС включает ограниченный набор датчиков, обеспечивающих измерение агрегированных макропараметров

состояния системы. Ограничение числа датчиков обусловлено требованиями к массогабаритным характеристикам транспортного средства, а также сложностью размещения измерительных устройств в условиях глубокого вакуума и криогенных температур. Структура измерительной системы МКС представлена на Рисунке 2.1.




Рисунок 2.1 – Структура измерительной системы многослойной криогенной системы

Сенсорная подсистема МКС формально определяется кортежем (2.9).

$$S = \langle x_1, x_2, x_3, x_4, x_5 \rangle = \langle S_{status}, L_{He}, P_{He}, L_{N_2}, P_{N_2} \rangle, \quad (2.9)$$

где $x_1 = S_{status}$ – статус контейнера, принимающий значения 0 (контейнер в пути, транспортировка) или 1 (контейнер в покое, хранение на станции), определяемый по данным навигационной системы;

$x_2 = L_{He}$ – уровень жидкого гелия во внутреннем сосуде, измеряемый сверхпроводящим уровнемером в диапазоне 0–100 % с погрешностью $\pm 1\%$, принцип действия которого основан на изменении сопротивления сверхпроводящей проволоки при погружении в жидкий гелий;

$x_3 = P_{He}$ – давление насыщенных паров гелия во внутреннем сосуде, измеряемое криогенным тензодатчиком в диапазоне 0–0,5 МПа с погрешностью $\pm 0,5 \%$;

$x_4 = L_{N_2}$ – уровень жидкого азота в азотной полости, измеряемый емкостным уровнемером в диапазоне 0–100 % с погрешностью $\pm 1 \%$;

$x_5 = P_{N_2}$ – давление азота в азотной полости, измеряемое пьезорезистивным датчиком в диапазоне 0–1,0 МПа с погрешностью $\pm 0,5 \%$ (см. Таблицу 2.1). Частота опроса датчиков составляет 1–10 Гц в зависимости от типа. Характеристики измерительной системы МКС обобщены в Таблице 2.1.

Таблица 2.1 – Характеристики измерительной системы МКС

Параметр	Датчик	Диапазон	Относительная погрешность измерения	Физический принцип
S_{status}	Навигационная система	0/1	–	Позиционирование
L_{He}	Сверхпроводящий уровнемер	0–100 %	$\pm 1 \%$	Изменение сопротивления
P_{He}	Криогенный тензодатчик	0–0,5 МПа	$\pm 0,5 \%$	Тензометрия
L_{N_2}	Емкостной уровнемер	0–100 %	$\pm 1 \%$	Изменение емкости
P_{N_2}	Пьезорезистивный датчик	0–1,0 МПа	$\pm 0,5 \%$	Пьезоэффект

Комплект датчиков является минималистичным. Его достаточно для диспетчеризации, то есть для отслеживания местоположения и общего состояния груза, но недостаточно для детальной диагностики дефектов изоляции на ранней стадии. Расширение измерительной системы сопряжено со значительными техническими и экономическими затратами, поэтому задача состоит в извлечении максимума информации из имеющихся данных.

Измерительная система МКС обеспечивает наблюдение пяти агрегированных параметров $S = \langle x_1, \dots, x_5 \rangle$. В то время как истинное состояние системы Z определяется существенно большим числом переменных. К

ненаблюдаемым параметрам относятся пространственное распределение температуры в изоляции $T(x, y, z)$, локальные дефекты вакуумной изоляции (микротечи, участки дегазации), состояние элементов подвески (деформации, термические мосты), распределение жидкой и газовой фаз криогенного продукта при динамических нагрузках. Формально связь между истинным состоянием системы Z и вектором измерений X_{raw} описывается соотношением (2.10).

$$X_{raw} = Pr(Z) + \varepsilon, \quad (2.10)$$

где X_{raw} – вектор наблюдаемых параметров, формируемый измерительной системой;

Z – полное (истинное) состояние системы, включающее все физические параметры;

$Pr: Z \rightarrow R^5$ – оператор проецирования, отображающий полное состояние системы на пять наблюдаемых макропараметров;

ε – вектор погрешностей измерений, обусловленных инструментальной погрешностью датчиков сенсорной подсистемы.

Соотношение (2.10) формализует проблему неполной наблюдаемости, которая является фундаментальным ограничением при диагностике состояния МКС. Невозможность прямого измерения всех физических параметров системы обуславливает необходимость применения методов косвенной оценки состояния на основе доступных измерений.

Классический подход к диагностике состояния МКС основан на решении системы дифференциальных уравнений в частных производных, описывающих тепло- и массоперенос в многослойной среде. Тепловой баланс изоляции подчиняется уравнению теплопроводности (2.11).

$$\rho(T) \cdot c(T) \cdot \frac{\partial T}{\partial t} = \nabla \cdot (\lambda(T) \cdot \nabla T) + Q_{int}, \quad (2.11)$$

где $\rho(T)$ – плотность материала изоляции, зависящая от температуры, кг/м^3 ;

$c(T)$ – удельная теплоемкость материала, Дж/(кг·К);

T – температура, К;

t – время, с;

$\lambda(T)$ – коэффициент теплопроводности, Вт/(м·К);

∇ – оператор набла (градиент);

Q_{int} – внутренняя теплогенерация (как правило, равна нулю для пассивной изоляции), Вт/м³.

Уравнение (2.11) является отправной точкой детерминированного подхода к описанию теплового состояния МКС.

Для численного решения уравнения (2.11) применяется конечно-разностная аппроксимация. В простейшем одномерном случае (плоское приближение) при использовании явной схемы Эйлера пространственная область разбивается на N_r узлов с шагом Δr , а временная на шаги Δt (2.12).

$$T_i^{n+1} = T_i^n + \frac{\Delta t}{\rho_i \cdot c_i} \left[\lambda_i \cdot \frac{T_{i+1}^n - 2T_i^n + T_{i-1}^n}{(\Delta r)^2} \right], \quad (2.12)$$

где T_i^n – температура в i -м узле на n -м временном шаге.

Плоское приближение допустимо, поскольку толщина МЭВИ (30–50 мм) пренебрежимо мала по сравнению с радиусом сосуда ($\sim 1,2$ м), и отношение толщины к радиусу не превышает 0,04.

Условие устойчивости явной схемы (условие Куранта–Фридрихса–Леви) налагает ограничение на временной шаг (2.13).

$$\Delta t \leq \frac{(\Delta r)^2 \cdot \rho \cdot c}{2\lambda}. \quad (2.13)$$

Для многослойной экранно-вакуумной изоляции (МЭВИ) с характерной толщиной 30–50 мм и числом слоев порядка 40 необходимое пространственное разрешение составляет $\Delta r \approx 0,5$ мм ($N_r \approx 100$ узлов). С учётом теплофизических свойств материалов при криогенных температурах ($\lambda \approx 0,01$ Вт/(м·К), $\rho \cdot c \approx 10^3$

Дж/(м³·К)) условие устойчивости дает $\Delta t \leq 0,0125$ с. Для моделирования процесса длительностью 1 час требуется $N_t = 3600/0,0125 = 288\,000$ временных шагов. Число операций одной итерации составляет (2.14).

$$N_r \cdot N_t = 2,88 \cdot 10^7. \quad (2.14)$$

Тестирование упрощенной одномерной конечно-разностной схемы на контроллере STM32F4 (168 МГц, архитектура ARM Cortex-M4) показало, что реализация модели занимает 180 КБ флэш-памяти (при общем объеме 256 КБ) и требует более 2 секунд на одну итерацию. Время формирования управляющего воздействия в бортовой системе МКС ограничено величиной $\Psi_{time} = 50$ мс, что означает превышение допустимого времени более чем в 40 раз. Результаты тестирования представлены на Рисунке 2.2.




Рисунок 2.2 – Расчётная схема теплопереноса в многослойной системе

Помимо вычислительной неприемлемости, применение детерминированного численного решения уравнения (2.11) для задачи оперативной поддержки принятия решений сопряжено с тремя ограничениями.

Первое ограничение состоит в стохастичности параметров изоляции. Коэффициент теплопроводности $\lambda(T)$ зависит не только от температуры, но и от степени вакуума, которая изменяется случайным образом вследствие дегазации материалов МЭВИ и микронатеканий через сварные швы. При транспортировке дополнительный вклад вносят случайные микродеформации изоляции, изменяющие контакт между слоями МЭВИ. Коэффициент теплопроводности, таким образом, является не детерминированной функцией $\lambda(T)$, а случайной величиной $\lambda(T, \omega)$, где $\omega \in \Omega$ – элементарный исход из пространства случайных событий.

Второе ограничение связано с неконтролируемыми граничными условиями. Температура внешней оболочки определяется условиями окружающей среды, включая солнечную радиацию, температуру воздуха, скорость ветра, наличие осадков. Данные параметры варьируются в широких пределах и не контролируются бортовой системой мониторинга. Для корректного решения уравнения (2.11) необходимо задание граничных условий первого или третьего рода на внешней поверхности, что невозможно без информации о текущих метеоусловиях.

Третье ограничение обусловлено некорректностью обратной задачи по Адамару. Диагностика дефектов изоляции представляет собой обратную задачу идентификации параметров по ограниченным измерениям. Задача называется корректно поставленной в смысле Адамара, если одновременно выполняются три условия, а именно существование решения, единственность решения и непрерывная зависимость решения от входных данных. Обратная задача восстановления распределения $\lambda(r)$ по показаниям пяти датчиков S не удовлетворяет третьему условию. При относительной погрешности входных данных порядка 1 % (типичная погрешность датчиков, см. Таблицу 2.1) отклонения решения достигают десятков процентов, что делает результат непригодным для

принятия управленческих решений. Результаты тестирования детерминированного подхода обобщены в Таблице 2.2.

Таблица 2.2 – Результаты тестирования детерминированного подхода на контроллере STM32

Параметр	Значение	Ограничение ψ	Соответствие
Объем модели	180 КБ	256 КБ	Частично (70 % памяти)
Время итерации	более 2000 мс	50 мс	Не соответствует
Устойчивость к погрешностям	Отклонения десятки % при $\varepsilon = 1\%$	$\varepsilon \leq 10\%$	Не соответствует
Контролируемость граничных условий	Не обеспечена	Обязательна	Не соответствует

Автором разработана обобщающая схема, отражающая совокупность ограничений детерминированного подхода и обосновывающая переход к информационному подходу (см. Рисунок 2.3).



Рисунок 2.3 – Обоснование перехода от детерминированного к информационному подходу

Совокупность перечисленных ограничений обосновывает переход от детерминированной модели к информационному подходу на основе статистического обучения. При таком подходе неизвестная зависимость между показаниями датчиков и состоянием системы аппроксимируется по данным наблюдений, накопленным в процессе эксплуатации. Переход является концептуально значимым, поскольку меняет парадигму решения от моделирования физических процессов к извлечению закономерностей из накопленного опыта. Подход на основе статистического обучения обладает рядом преимуществ по сравнению с детерминированным моделированием. Стохастичность параметров неявно учитывается через обучение на представительной выборке, содержащей данные при различных условиях эксплуатации. Работа в реальном времени обеспечивается за счёт однократного офлайн-обучения модели, после которого вычислительная сложность формирования предсказания минимальна и составляет единицы миллисекунд. Экспертные знания о физике процессов интегрируются через конструирование информативных признаков, отражающих специфику предметной области.

Таким образом, задача оперативной поддержки принятия решений в управлении МКС формулируется как задача системного анализа и обработки информации, основанная на статистическом обучении по эмпирическим данным. Математическая формализация этой задачи как задачи классификации состояний и многокритериальной оптимизации с ограничениями составляет предмет дальнейшего рассмотрения.

2.2 Математическая модель классификации состояний многослойной криогенной системы как задача многокритериальной оптимизации с ограничениями

Обоснованный переход от детерминированного моделирования к информационному подходу на основе статистического обучения требует формализации задачи в терминах теории распознавания образов. Входными данными модели является вектор измерений $X_{raw} \in R^5$. Выходом модели является предсказание $\hat{Y} \in \{0,1\}$, соответствующее рекомендации системы поддержки принятия решений, где значение 0 означает «воздействие не требуется» (штатный режим), а значение 1 означает «рекомендуется долив азота» (предаварийный режим).

Общая структура математической модели классификации имеет вид (2.15).

$$\hat{Y} = f(X; \theta; \Psi), \quad (2.15)$$

где $X \in R^M$ – вектор признаков, используемый для классификации ($M \geq 5$);
 $f(\cdot; \theta)$ – решающее правило (классификатор) с настраиваемыми параметрами θ ;

Ψ – вектор физико-технических и вычислительных ограничений встраиваемой системы.

Вектор признаков X может совпадать с вектором исходных измерений X_{raw} при $M = 5$ либо являться результатом преобразования исходных измерений с целью повышения информативности признакового пространства при $M > 5$.

Принципиальной особенностью формулы (2.15) является явное включение вектора ограничений Ψ в определение модели. Данный вектор формально определяется кортежем (2.16).

$$\Psi = \langle t_{max}, V_{max}, R_{min}, I, \varepsilon \rangle, \quad (2.16)$$

где $t_{max} = 50$ мс – максимально допустимое время формирования одной рекомендации, обусловленное периодичностью цикла опроса датчиков бортовой системы;

$V_{max} = 256$ КБ – максимально допустимый объем оперативной памяти, занимаемый моделью, определяемый аппаратными ресурсами контроллера STM32F4;

$R_{min} = 0,95$ – минимально допустимое значение полноты (Recall), гарантирующее обнаружение не менее 95 % случаев, требующих управляющего воздействия;

I – требование интерпретируемости, означающее способность модели предоставлять оператору обоснование сформированной рекомендации в терминах измеряемых параметров МКС;

$\varepsilon = 0,10$ – допустимый уровень шума во входных данных, выраженный как доля от диапазона измерений и обусловленный погрешностью датчиков (Таблица 2.1) и механическими вибрациями при транспортировке.

Компоненты t_{max} и V_{max} представляют собой жесткие аппаратные ограничения, нарушение которых делает модель физически неразвертываемой на бортовом контроллере. Компонента R_{min} является жестким эксплуатационным ограничением, обусловленным критичностью пропуска предаварийного состояния. Компоненты I и ε являются качественными требованиями, обеспечивающими практическую применимость модели в условиях реальной эксплуатации.

На Рисунке 2.4 приведена общая схема задачи классификации состояний МКС – схема охватывает все этапы преобразования данных от сенсорной подсистемы до выработки управляющего решения.




Рисунок 2.4 – Общая схема задачи классификации состояний криогенной системы

Поскольку истинное совместное распределение $P(X, Y)$ неизвестно, минимизация теоретического риска $R(f)$ заменяется минимизацией эмпирического риска на обучающей выборке (2.17).

$$R_{emp}(f) = \frac{1}{N} \sum_{i=1}^N L(f(X_i), Y_i), \quad (2.17)$$

где N – объем обучающей выборки;

(X_i, Y_i) – пары «вектор признаков и метка класса» из обучающей выборки;

$L(\hat{Y}, Y)$ – функция потерь, количественно выражающая штраф за несовпадение предсказания модели с истинной меткой.

Учёт вектора ограничений Ψ превращает задачу минимизации эмпирического риска в задачу условной оптимизации (2.18):

$$\theta^* = \operatorname{argmin}_{\theta} R_{emp}(f) \quad \text{при ограничениях } \Psi. \quad (2.18)$$

От стандартной постановки задачи обучения выражение (2.18) отличает наличие вектора ограничений Ψ – за счёт него задача безусловной оптимизации превращается в задачу условной оптимизации. Допустимым считается лишь то решение θ^* , при котором одновременно выполняются все компоненты вектора Ψ .

Для задачи бинарной классификации используется логистическая функция потерь (бинарная кросс-энтропия) (2.19).

$$L(\hat{Y}, Y) = -[Y \cdot \ln(\hat{p}) + (1 - Y) \cdot \ln(1 - \hat{p})], \quad (2.19)$$

где $\hat{p} = P(Y = 1 | X)$ – предсказанная моделью вероятность принадлежности к классу «требуется воздействия»;

$Y \in \{0, 1\}$ – истинная метка класса.

Выбор логистической функции потерь обусловлен ее вероятностной интерпретацией и выпуклостью, гарантирующей единственность глобального минимума. Данная функция менее чувствительна к выбросам по сравнению с квадратичной функцией потерь, что существенно при работе с зашумленными данными датчиков.

В условиях эксплуатации МКС цена различных типов ошибок классификации существенно различается. Для формализации этого различия рассматривается матрица ошибок, содержащая четыре элемента. Элемент TP (истинно положительный результат) соответствует правильной классификации случая, требующего воздействия, то есть система корректно рекомендовала, долив азота, когда он действительно необходим. Элемент TN (истинно отрицательный результат) соответствует правильной классификации штатного состояния. Элемент FP (ложноположительный результат, ошибка первого рода) означает ложное срабатывание, когда система рекомендовала долив при отсутствии реальной необходимости. Последствия ограничиваются избыточной проверкой оператором и незначительными временными затратами порядка 15–30 минут. Элемент FN (ложноотрицательный результат, ошибка второго рода) соответствует пропуску события: рекомендация не сформирована при реальной необходимости долива. Последствия этой ошибки заметно тяжелее: при оголении азотного экрана теплоприток увеличивается в 250 раз (формула (2.5)), что ускоряет испарение жидкого гелия и оборачивается значительными экономическими потерями. Структура матрицы ошибок и асимметрия последствий приведены на Рисунке 2.5.




Рисунок 2.5 – Матрица ошибок классификации и асимметрия последствий

Соотношение последствий ошибок FN и FP составляет около 100 к 1, что и заставляет ввести асимметричную функцию потерь (2.20).

$$L_w(\hat{Y}, Y) = -[w_1 \cdot Y \cdot \ln(\hat{p}) + w_0 \cdot (1 - Y) \cdot \ln(1 - \hat{p})], \quad (2.20)$$

где w_1 – вес класса «требуется воздействие»;

w_0 – вес класса «не требуется воздействия».

При характерном для задачи соотношении классов (порядка 17 к 1) разумные значения весов – $w_1 = 19$, $w_0 = 1$. Такой подбор компенсирует дисбаланс и направляет обучение на лучшее распознавание редкого, но критически значимого класса.

Дисбаланс классов – отличительная черта задач мониторинга технических систем. В рассматриваемой выборке соотношение классов – порядка 17 к 1: на мажоритарный класс «не требуется воздействия» приходится около 95 % наблюдений.

Причина дисбаланса заключена в физике процессов, протекающих в МКС: жидкий азот испаряется постепенно (суточные потери – 0,5–1 % от объёма), и необходимость долива возникает относительно редко – один раз в несколько суток при типичных условиях эксплуатации. В условиях дисбаланса классов метрика

доли правильных ответов теряет информативность: классификатор, всегда предсказывающий мажоритарный класс ($Y = 0$), достигает значения 95 %, но для практической задачи бесполезен – все случаи, требующие воздействия, остаются пропущенными.

При работе с несбалансированными данными, помимо асимметричной функции потерь (2.20), применяются стратифицированное разбиение и оптимизация порога классификации. Стратифицированное разбиение сохраняет исходное соотношение классов в обучающей и тестовой выборках. Оптимизация порога классификации предполагает отказ от стандартного значения 0,5 в пользу того, которое максимизирует целевую метрику на валидационной выборке.

Для оценки качества классификатора в условиях дисбаланса классов и асимметрии ошибок используется система метрик, основанных на матрице ошибок. Точность (Precision) определяется как доля истинно положительных среди всех положительных предсказаний (2.21).

$$\text{Precision} = \frac{TP}{TP + FP}. \quad (2.21)$$

Полнота (Recall) определяется как доля обнаруженных положительных случаев среди всех истинно положительных (2.22).

$$\text{Recall} = \frac{TP}{TP + FN}. \quad (2.22)$$

Гармоническое среднее точности и полноты (F_1 -мера) определяется выражением (2.23).

$$F_1 = \frac{2 \cdot \text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}. \quad (2.23)$$

F_1 -мера является основной метрикой для сравнения классификаторов в рассматриваемой задаче, поскольку учитывает как точность, так и полноту, при этом штрафует модели с сильным перекосом в одну из сторон. Гармоническое

среднее ближе к меньшему из двух значений, что предотвращает завышение оценки при низкой полноте. Компонента R_{min} вектора ограничений Ψ накладывает дополнительное жесткое ограничение, означающее, что модель допустима только при $\text{Recall} \geq 0,95$.

Дополнительной характеристикой качества является кривая ROC, отображающая зависимость доли истинно положительных результатов от доли ложноположительных при различных порогах классификации. Площадь под кривой ROC характеризует способность модели различать классы независимо от выбора порога. Значение 0,5 соответствует случайному классификатору, значение 1,0 соответствует идеальному. В условиях сильного дисбаланса классов более информативной оказывается кривая «точность–полнота»: истинно отрицательные результаты, число которых при редком положительном классе доминирует, в этой метрике не учитываются.

Когда выборка ограничена сотнями наблюдений, неминуемо встаёт проблема переобучения: модель запоминает шум обучающих данных и теряет способность обобщать. Стандартный приём борьбы с этим – регуляризация, добавление к функции потерь штрафа за сложность модели (2.24):

$$J(\theta) = R_{emp}(f) + \lambda \cdot \Omega(\theta), \quad (2.24)$$

где $\lambda \geq 0$ – коэффициент регуляризации;

$\Omega(\theta)$ – регуляризационный член. В гребневой регрессии (L2) штрафом служит квадрат евклидовой нормы вектора параметров (2.25):

$$\Omega_{L2}(\theta) = \|\theta\|_2^2 = \sum_j \theta_j^2. \quad (2.25)$$

L2-регуляризация подтягивает веса к нулю, но не обнуляет их полностью. Метод хорошо себя показывает при наличии коррелированных признаков и придаёт решению устойчивость.

В лассо (L1) используется сумма абсолютных значений параметров (2.26):

$$\Omega_{L1}(\theta) = \|\theta\|_1 = \sum_j |\theta_j|. \quad (2.26)$$

Лассо обнуляет веса незначимых признаков – то есть автоматически отбирает признаки. Это повышает интерпретируемость модели, что согласуется с компонентой I вектора ограничений Ψ .

Эластичная сеть совмещает оба подхода (2.27):

$$\Omega_{EN}(\theta) = \alpha \cdot \|\theta\|_1 + (1 - \alpha) \cdot \|\theta\|_2^2, \quad (2.27)$$

где $\alpha \in [0,1]$ – параметр смешивания. Коэффициент регуляризации λ подбирается методом кросс-валидации. Малые значения λ ведут к переобучению (высокая дисперсия, низкое смещение), большие – к недообучению (низкая дисперсия, высокое смещение). Оптимальное значение λ даёт баланс смещения и дисперсии.

Качество модели и выбор гиперпараметров при ограниченном объёме данных оценивают с помощью стратифицированной k -кратной кросс-валидации. Выборка разбивается на k непересекающихся частей (фолдов) – соотношение классов в каждом фолде сохраняется. Модель обучается k раз; каждый раз $(k - 1)$ фолдов задействуются для обучения, а оставшийся – для валидации. Итоговая оценка качества определяется как среднее по k экспериментам (2.28):

$$\text{Score}_{cv} = \frac{1}{k} \sum_{i=1}^k \text{Score}_i, \quad (2.28)$$

где Score_i – значение метрики на i -м фолде. Стандартное отклонение по фолдам показывает устойчивость модели. Для задачи классификации состояний МКС с выборкой до 1000 наблюдений берётся $k = 5$ или $k = 10$. Стратификация критически важна при выраженном дисбалансе классов, поскольку гарантирует наличие представителей редкого класса в каждом фолде.

Задача классификации состояний МКС формулируется как задача многокритериальной оптимизации с ограничениями. Подход, при котором требования регуляторного и эксплуатационного характера формализуются как ограничения оптимизационной задачи, ранее применялся автором при разработке математических моделей оптимизации машиночитаемых регулятивных систем [23] и в настоящей работе развит применительно к задаче классификации состояний криогенного оборудования. Требуется найти параметры модели θ , обеспечивающие компромисс между метриками качества при соблюдении вектора ограничений Ψ (2.29), (2.30), (2.31).

$$J_1 = 1 - \text{Recall} \rightarrow \min, \quad (2.29)$$

$$J_2 = 1 - \text{Precision} \rightarrow \min, \quad (2.30)$$

$$J_3 = 1 - F_1 \rightarrow \min \quad (2.31)$$

при ограничениях (2.32), (2.33), (2.34).

$$\text{Latency}(f) \leq \Psi_1 = 50 \text{ мс}, \quad (2.32)$$

$$\text{Memory}(f) \leq \Psi_2 = 256 \text{ КБ}, \quad (2.33)$$

$$\text{Recall}(f) \geq \Psi_3 = 0,95. \quad (2.34)$$

Критерии J_1 , J_2 , J_3 являются конкурирующими. Повышение полноты (снижение J_1) при фиксированном пороге классификации, как правило, приводит к снижению точности (увеличению J_2). Задача многокритериальной оптимизации в общем случае не имеет единственного решения. Множество Парето-оптимальных решений определяется как совокупность допустимых решений, для которых невозможно улучшить ни один критерий без ухудшения хотя бы одного другого. Выбор конкретного решения из множества Парето осуществляется с учётом приоритета полноты (J_1), обусловленного асимметрией ошибок. Критерий J_3 функционально зависит от J_1 и J_2 через определение F_1 -меры (формула 2.23),

однако его явное включение исключает вырожденные решения Парето-фронта, при которых одна метрика максимальна за счёт другой. Схема многокритериальной оптимизации с ограничениями представлена на Рисунке 2.6.




Рисунок 2.6 – Схема многокритериальной оптимизации с ограничениями

На основе анализа физики процессов в МКС и характеристик бортовой системы управления формулируются требования к алгоритму классификации, представленные в Таблице 2.3.

Таблица 2.3 – Требования к алгоритму классификации (вектор ограничений Ψ)

Компонента Ψ	Требование	Значение	Обоснование
t_{max}	Время формирования рекомендации	≤ 50 мс	Цикл опроса бортовой системы
V_{max}	Объем оперативной памяти модели	≤ 256 КБ	Ресурсы контроллера STM32F4
R_{min}	Полнота (Recall)	$\geq 0,95$	Критичность пропуска события
I	Интерпретируемость	Обязательна	Обоснование рекомендации оператору
ε	Устойчивость к шуму	≤ 10 % от диапазона	Погрешность датчиков, вибрации

Требование интерпретируемости обусловлено спецификой системы поддержки принятия решений. Окончательное решение о выполнении управляющего воздействия (долив азота) принимает оператор, и модель должна не только формировать рекомендацию, но и предоставлять обоснование того, какие параметры системы привели к данной рекомендации. Требование устойчивости к шуму обусловлено погрешностями измерительной системы (Таблица 2.1), а также механическими вибрациями при транспортировке, создающими дополнительный шум в показаниях.

Отдельным требованием является способность алгоритма работать с обучающей выборкой малого объема (500–1000 наблюдений). В отличие от задач обработки изображений или текстов, где доступны миллионы примеров, данные о состоянии МКС накапливаются медленно, поскольку один рейс длится несколько суток. Алгоритм также должен допускать интеграцию экспертных знаний о физике теплопереноса через использование специально сконструированных признаков.

Рассматриваются три класса моделей, потенциально совместимых с вектором ограничений Ψ , а именно логистическая регрессия, случайный лес и градиентный бустинг. Варианты ядра модели классификации и их основные характеристики представлены на Рисунке 2.7.




Рисунок 2.7 – Варианты ядра модели классификации

Предварительная оценка соответствия методов требованиям вектора Ψ выполнена в Таблице 2.4.

Таблица 2.4 – Сравнительная характеристика методов классификации

Критерий	Логистическая регрессия	Случайный лес	Градиентный бустинг
Время отклика	менее 1 мс	10–20 мс	15–25 мс
Объем памяти	около 1 КБ	50–150 КБ	80–200 КБ
Полнота (Recall)	0,90–0,95	0,93–0,98	0,95–0,99
Интерпретируемость	высокая	средняя	средняя
Устойчивость к шуму	средняя	высокая	высокая
Работа с малой выборкой	высокая	средняя	средняя

Результаты сравнения показывают, что все три метода удовлетворяют жестким аппаратным ограничениям Ψ_1 и Ψ_2 . По критерию полноты $R_{min} = 0,95$ логистическая регрессия находится на границе допустимости, тогда как ансамблевые методы обеспечивают запас. Сравнительный анализ комбинирования линейной регрессии и случайного леса для задач интеллектуальной поддержки управления криогенными транспортными системами выполнен автором в [21], где экспериментально подтверждено преимущество ансамблевого подхода над линейными моделями в условиях нелинейных пороговых эффектов, характерных для МКС. Соответствие методов требованиям вектора Ψ обобщено на Рисунке 2.8.

Требование	Логистическая регрессия	Случайный лес	Градиентный бустинг
Время отклика ≤ 50 мс	✓✓ <1 мс	✓ 10–20 мс	✓ 15–25 мс
Память ≤ 256 КБ	✓✓ ~1 КБ	✓ 50–150 КБ	✓ 80–200 КБ
Интерпретируемость	✓✓ Высокая	✓ Средняя (ВП)	△ Анализ вкладов
Устойчивость к шуму	✗ Низкая	✓✓ Высокая	✓ Средняя
Точность (F1)	△ 0,65–0,85	✓✓ 0,90–0,93	✓✓ 0,90–0,93
Нелинейность	✗ Нет	✓ Да	✓ Да
Дисбаланс классов	△ Взвешивание	✓ Устойчив	△ Настройка
ИТОГ	Базовая модель Интерпретируемость	РЕКОМЕНДУЕТСЯ Баланс критериев	Максимальная точность Анализ вкладов

✓✓ Отлично ✓ Соответствует △ Частично ✗ Не соответствует

Рисунок 2.8 – Соответствие методов требованиям вектора ограничений

Разработанная математическая постановка задачи классификации (2.15)–(2.34) обеспечивает формальную основу для решения задачи поддержки принятия решений в управлении МКС. Учтены специфические особенности предметной области, а именно асимметрия ошибок с соотношением последствий 100 к 1, дисбаланс классов порядка 17 к 1, ограничения вычислительных ресурсов бортового контроллера. Введенный вектор ограничений $\Psi = \langle t_{max}, V_{max}, R_{min}, I, \varepsilon \rangle$ формализует условия допустимости модели и позволяет выполнить отбор совместимых алгоритмов. Три отобранных метода (логистическая регрессия, случайный лес, градиентный бустинг) составляют множество допустимых моделей, на котором выполняется дальнейшая оптимизация с учётом формирования информативного признакового пространства.

2.3 Формализация задачи формирования признакового пространства и отбор допустимых моделей классификации

Математическая модель классификации $\hat{Y} = f(X; \theta; \Psi)$ предполагает, что вектор признаков $X \in \mathbb{R}^M$ может быть результатом преобразования исходного

вектора измерений $X_{raw} \in \mathbb{R}^5$. Каким именно должно быть это преобразование – самостоятельная задача, от решения которой существенно зависит качество итоговой модели.

Корректность применения модели классификации определяется не только качеством признаков, но и частотой обновления информации о состоянии объекта управления. Период опроса датчиков должен быть достаточным для обнаружения значимых изменений состояния МКС до наступления критической ситуации. Максимальная скорость испарения азота в штатном режиме эксплуатации составляет 0,58 % от номинального объема в час. Минимально детектируемое изменение уровня азота определяется относительной погрешностью емкостного уровнемера. Согласно правилу трёх стандартных отклонений (3σ) при погрешности $\pm 1\%$ минимально детектируемое изменение составляет $\Delta L_{min} = 3\%$. Время, за которое уровень азота изменяется на минимально детектируемую величину, определяется соотношением (2.35).

$$T_{change} = \frac{\Delta L_{min}}{v_{max}} = \frac{3\%}{0,58\%/ч} \approx 5,2 \text{ ч.} \quad (2.35)$$

Для обнаружения изменений уровня, превышающих относительную погрешность датчика, период дискретизации не должен превышать половины характерного времени изменения сигнала (2.36).

$$T_{sample} \leq \frac{T_{change}}{2}. \quad (2.36)$$

Подстановка значения $T_{change} = 5,2$ ч дает верхнюю границу периода опроса $T_{sample} \leq 2,6$ ч. Принят штатный период опроса 2 часа с двукратным запасом. При снижении уровня азота ниже 20 % от номинального объема период опроса сокращается до 15 минут для повышения оперативности обнаружения критических состояний.

Исходное пространство измерений R^n (где $n = 5$ для МКС) содержит агрегированные макропараметры состояния системы, определенные вектором $S = \langle x_1, \dots, x_5 \rangle$. Анализ задачи классификации показывает, что исходное пространство не обеспечивает достаточной разделимости классов для моделей, совместимых с вектором ограничений Ψ . Физические эффекты, определяющие переход системы из штатного состояния в состояние, требующее вмешательства, носят нелинейный и пороговый характер, что обосновано при анализе закона Стефана–Больцмана и роли азотного экрана. Эти эффекты не выражаются линейными комбинациями исходных параметров, а значит, простые модели (в первую очередь логистическая регрессия) не способны адекватно их отразить без предварительного обогащения признакового пространства.

Вводится оператор преобразования признаков Φ в общем виде (2.37).

$$\Phi: R^n \rightarrow R^M, \quad M > n, \quad (2.37)$$

где n – размерность исходного пространства измерений;

M – размерность расширенного признакового пространства;

Φ – оператор, сохраняющий исходные n компонент и добавляющий $M - n$ производных признаков.

К оператору Φ предъявляются три формальных требования. Первое требование состоит в повышении разделимости классов. Преобразование Φ должно увеличивать степень линейной разделимости классов в расширенном пространстве по сравнению с исходным (2.38).

$$J(\Phi(X)) > J(X), \quad (2.38)$$

где J – мера линейной разделимости, определяемая как отношение межклассового рассеяния к внутриклассовому (критерий Фишера).

Для задачи бинарной классификации ($Y \in \{0,1\}$) мера J вычисляется как (2.39).

$$J = \frac{(\mu_1 - \mu_0)^2}{\sigma_1^2 + \sigma_0^2}, \quad (2.39)$$

где

μ_0, μ_1 – средние значения проекций объектов классов 0 и 1 на оптимальную разделяющую прямую;

σ_0^2, σ_1^2 – дисперсии проекций внутри каждого класса.

Второе требование – физическая обоснованность. Каждый производный признак $\varphi_k(X_{raw}), k = n + 1, \dots, M$, должен иметь содержательную интерпретацию в терминах физики процессов теплопереноса в МКС. Это требование обеспечивает прозрачность модели для оператора и исключает появление вычислительных артефактов, не имеющих физического смысла.

Третье требование – совместимость с ресурсными ограничениями. Вычисление оператора $\Phi(X_{raw})$ должно выполняться в рамках ограничений вектора $\Psi = \langle t_{max}, V_{max}, R_{min}, I, \varepsilon \rangle$, а именно время вычисления Φ не должно существенно увеличивать латентность обработки данных, а объем дополнительной памяти для хранения промежуточных результатов должен быть пренебрежимо мал.

Задача формирования признакового пространства формулируется как оптимизационная (2.40).

$$\Phi^* = \operatorname{argmax}_{\Phi} J(\Phi(X)) \quad \text{при} \quad t(\Phi) \leq t_{max}, \quad V(\Phi) \leq V_{max}, \quad (2.40)$$

где Φ^* – оптимальный оператор преобразования;

$J(\Phi(X))$ – мера разделимости в расширенном пространстве;

$t(\Phi)$ – время вычисления оператора;

$V(\Phi)$ – объем памяти, необходимый для вычисления оператора.

Формулировка (2.40) задает математический каркас, в рамках которого конструирование конкретных производных признаков на основе физики криогенных процессов и количественная валидация их вклада составляют предмет разработки алгоритма формирования признакового пространства.

Вектор ограничений $\Psi = \langle t_{max}, V_{max}, R_{min}, I, \varepsilon \rangle$ определяет область допустимых решений в пространстве моделей. Не все методы машинного обучения совместимы с этими ограничениями, и процедура отбора сводится к последовательной проверке совместимости каждого метода с компонентами вектора Ψ .

Обоснование применимости простых (вычислительно нетребовательных) моделей машинного обучения для прогнозирования управленческих решений в многослойных криогенных системах с ограниченными вычислительными ресурсами выполнено автором в [30]. Современные методы обучения с учителем для задачи бинарной классификации включают широкий спектр алгоритмов. Глубокие нейронные сети обеспечивают наивысшую точность на больших выборках, однако требуют графических ускорителей и объемов оперативной памяти порядка десятков мегабайт, что превышает ограничение $V_{max} = 256$ КБ на два порядка. Кроме того, для их обучения необходимы выборки объемом порядка 10^5 – 10^6 наблюдений, тогда как в задаче МКС доступно порядка 700 наблюдений. Метод опорных векторов в нелинейном варианте (с ядрами) требует хранения опорных векторов, число которых может достигать значительной доли от объема обучающей выборки, и не обеспечивает прямой интерпретируемости решений. Методы автоматической генерации признаков порождают пространство размерности $O(n^k)$, несовместимое с ограничениями Ψ по времени и памяти.

После исключения несовместимых методов в области допустимых решений остаются три класса моделей, удовлетворяющих всем компонентам вектора Ψ .

Логистическая регрессия является линейным классификатором, предсказывающим вероятность принадлежности объекта к положительному классу с помощью сигмоидной функции (2.41).

$$\hat{p} = \sigma(z) = \frac{1}{1 + e^{-z}}, \quad z = \theta^T X + \theta_0, \quad (2.41)$$

где $\theta \in \mathbb{R}^M$ – вектор весов признаков;

θ_0 – свободный член модели;

$\sigma(z)$ – сигмоидная функция, отображающая $R \rightarrow (0,1)$.

Решающее правило классификатора определяется как (2.42).

$$\hat{Y} = I(\hat{p} \geq T), \quad (2.42)$$

где T – порог классификации (по умолчанию $T = 0,5$),

$I(\cdot)$ – индикаторная функция.

Параметры модели находятся путем минимизации кросс-энтропии с L2-регуляризацией (2.43).

$$J(\theta) = -\frac{1}{N} \sum_{i=1}^N [Y_i \ln(\hat{p}_i) + (1 - Y_i) \ln(1 - \hat{p}_i)] + \lambda \|\theta\|_2^2, \quad (2.43)$$

где N – число объектов в обучающей выборке;

$Y_i \in \{0,1\}$ – истинная метка класса i -го объекта;

$\hat{p}_i$ – предсказанная вероятность для i -го объекта;

$\lambda \geq 0$ – коэффициент регуляризации.

Градиент функции потерь имеет вид (2.44).

$$\nabla_{\theta} J(\theta) = \frac{1}{N} \sum_{i=1}^N (\hat{p}_i - Y_i) X_i + 2\lambda \theta, \quad (2.44)$$

и оптимальный вектор θ^* находится итерационным методом L-BFGS по условию $\nabla_{\theta} J(\theta) = 0$. Знак и величина коэффициента θ_j непосредственно показывают направление и силу влияния j -го признака на вероятность положительного класса, что обеспечивает максимальную интерпретируемость среди рассматриваемых методов. Вычислительная сложность вывода составляет $O(M)$, время отклика на контроллере менее 1 мс, объем памяти порядка 1 КБ.

Случайный лес представляет собой ансамбль решающих деревьев, каждое из которых обучается на бутстрэп-выборке из исходных данных с использованием

случайного подмножества признаков. Решающее правило ансамбля формируется голосованием большинством (2.45).

$$\hat{Y} = \text{mode}\{h_1(X), h_2(X), \dots, h_T(X)\}, \quad (2.45)$$

где $h_t(X)$ – предсказание t -го дерева;

T – число деревьев в ансамбле.

Критерий выбора признака и порога разделения в каждом узле дерева основан на минимизации неоднородности (индекс Джини) (2.46).

$$G = 1 - \sum_k p_k^2, \quad (2.46)$$

где p_k – доля объектов k -го класса в узле.

Для бинарной классификации индекс Джини достигает максимума $G = 0,5$ при равном распределении классов и минимума $G = 0$ при полной однородности. Построение каждого дерева включает формирование бутстрэп-выборки размера N , случайный выбор m признаков из M доступных (типично $m = \sqrt{M}$) на каждом шаге разбиения, поиск наилучшего порога по критерию Джини и рекурсивное разбиение до достижения условия остановки.

Надежность ансамбля имеет строгое теоретическое обоснование. Если ансамбль составлен из T независимых классификаторов h_t с одинаковой вероятностью ошибки $p < 0,5$, то вероятность ошибки ансамбля при голосовании большинством имеет верхнюю оценку (2.47).

$$P_{err}(\text{ансамбль}) \leq \exp(-2T \cdot (0,5 - p)^2). \quad (2.47)$$

Из (2.47) видно, что ошибка ансамбля убывает экспоненциально по мере роста числа деревьев T . При этом формула (2.47) исходит из предположения о независимости классификаторов. В случайном лесе деревья слабо коррелированы в силу пересечения бутстрэп-выборок; случайный отбор признаков при каждом

разбиении дополнительно ослабляет корреляцию и приближает поведение ансамбля к теоретической оценке.

Для выхода на заданный уровень ошибки $P_{\text{err}} < \delta$ достаточно (2.48).

$$T \geq \frac{\ln(1/\delta)}{2 \cdot (0,5-p)^2}. \quad (2.48)$$

Так, при $p = 0,3$ и $\delta = 0,01$ достаточно $T \geq 58$ деревьев. На практике применяется $T = 100\text{--}500$ деревьев с ограничением по глубине – без такого ограничения объём памяти выходит за допустимые рамки. Случайный лес устойчив к шуму благодаря усреднению предсказаний независимых моделей; кроме того, он даёт возможность оценить важность признаков – как среднее уменьшение неоднородности при разбиении по каждому из них. Время отклика на контроллере составляет 10–20 мс, объём памяти 50–150 КБ в зависимости от числа и глубины деревьев.

Градиентный бустинг строит аддитивную модель, где каждое последующее дерево обучается на псевдо-остатках предыдущего ансамбля (2.49).

$$F_m(X) = F_{m-1}(X) + \eta \cdot h_m(X), \quad (2.49)$$

где $F_m(X)$ – предсказание ансамбля после добавления m -го дерева;

$\eta \in (0,1]$ – коэффициент скорости обучения;

$h_m(X)$ – m -е дерево, обученное на градиентах функции потерь.

Решающее правило итогового ансамбля из T деревьев имеет вид (2.50).

$$F_T(X) = \sum_{t=1}^T \eta \cdot h_t(X). \quad (2.50)$$

Малые значения η (0,01–0,1) замедляют обучение, но повышают обобщающую способность модели. На каждой итерации дерево h_m аппроксимирует антиградиент функции потерь (2.51).

$$h_m = \operatorname{argmin}_h \sum_{i=1}^N [-g_i - h(X_i)]^2, \quad (2.51)$$

где $g_i = \partial L / \partial F_{m-1}(X_i)$ – градиент функции потерь по предсказанию ансамбля на i -м объекте.

Градиентный бустинг обеспечивает наивысшую точность среди рассматриваемых методов, однако менее устойчив к переобучению и требует тщательной настройки гиперпараметров (η , число деревьев T , максимальная глубина). Время отклика на контроллере составляет 15–25 мс, объем памяти 80–200 КБ.

Для каждой из трёх моделей-кандидатов выполнена проверка совместимости с компонентами вектора ограничений Ψ . Результаты верификации обобщены в Таблице 2.5.

Таблица 2.5 – Отобранные модели классификации и проверка совместимости с Ψ

Модель	Время отклика	$\Psi_1 \leq 50$ мс	Память	$\Psi_2 \leq 256$ КБ	Полнота	$\Psi_3 \geq 0,95$
Логистическая регрессия	< 1 мс	✓	~ 1 КБ	✓	Определяется обучением	–
Случайный лес	10–20 мс	✓	50–150 КБ	✓	Определяется обучением	–
Градиентный бустинг	15–25 мс	✓	80–200 КБ	✓	Определяется обучением	–

Все три модели удовлетворяют ограничениям по времени отклика Ψ_1 и объему памяти Ψ_2 . Ограничение по полноте $\Psi_3 \geq 0,95$ верифицируется на этапе обучения и зависит от качества обучающей выборки и признакового пространства. Выполнение Ψ_3 не может быть гарантировано априори и подлежит экспериментальной проверке.

Логистическая регрессия обладает наименьшей вычислительной сложностью и наивысшей интерпретируемостью, однако является линейным классификатором и не способна адекватно отразить нелинейные и пороговые зависимости,

характерные для процессов в МКС, без предварительного обогащения признакового пространства. Случайный лес обеспечивает баланс между точностью, устойчивостью к шуму и интерпретируемостью, а также естественным образом учитывает нелинейные зависимости за счёт древовидной структуры моделей. Градиентный бустинг обеспечивает максимальную точность за счёт последовательной коррекции ошибок, однако менее устойчив к шуму и требует специальных методов для обеспечения интерпретируемости решений.

Сформулирована задача формирования признакового пространства как задача оптимизации оператора преобразования Φ при ресурсных ограничениях Ψ , обоснована периодичность опроса датчиков на основе теоремы отсчетов Найквиста–Шеннона и выполнен отбор трёх допустимых моделей классификации, совместимых с ограничениями бортового контроллера. Полученные результаты составляют математическую основу для разработки конкретного алгоритма формирования признаков и обучения модели классификации.

Выводы по главе 2

Во второй главе выполнена физико-математическая постановка задачи обработки информации в системе управления многослойной криогенной системой. Получены следующие основные результаты.

1. Проведен анализ применимости детерминированного подхода к задаче определения состояния экранирующего слоя МКС на основе численного решения уравнения теплопроводности. Тестирование конечно-разностной схемы на контроллере STM32 показало, что модель занимает 180 КБ памяти и требует более 2 секунд на итерацию при ограничении $t_{max} = 50$ мс. Выявлены три ограничения детерминированного подхода, а именно стохастичность параметров изоляции, неконтролируемость граничных условий и некорректность обратной задачи по Адамару. Совокупность этих ограничений обосновала переход от детерминированной модели к информационному подходу на основе

статистического обучения.

2. Разработана математическая модель классификации состояний МКС $\hat{Y} = f(X; \theta; \Psi)$ как задача многокритериальной оптимизации с ограничениями. Принципиальной особенностью модели является явное включение вектора физико-технических ограничений $\Psi = \langle t_{max}, V_{max}, R_{min}, I, \varepsilon \rangle$ в формальную постановку задачи, что расширяет стандартную архитектуру модели классификации и обеспечивает верифицируемость решения на этапе проектирования. Введена асимметричная функция потерь L_w , отражающая различие последствий ошибок первого и второго рода при соотношении $\alpha/\beta \approx 100$, что формально обосновывает требование $R_{min} \geq 0,95$.

3. Обоснована периодичность опроса датчиков МКС на основе теоремы отсчетов Найквиста–Шеннона. При максимальной скорости испарения азота 0,58 %/ч и минимально детектируемом изменении $\Delta L_{min} = 3\%$ (правило 3σ при погрешности $\pm 1\%$) время значимого изменения составляет $T_{change} \approx 5,2$ ч, что дает верхнюю границу периода опроса $T_{sample} \leq 2,6$ ч. Принят штатный период 2 часа с переходом к 15-минутному интервалу при уровне азота ниже 20 %.

4. Формализована задача формирования признакового пространства как задача оптимизации оператора преобразования $\Phi^* = \operatorname{argmax}_{\Phi} J(\Phi(X))$ при ресурсных ограничениях $t(\Phi) \leq t_{max}$, $V(\Phi) \leq V_{max}$. К оператору Φ предъявлены три формальных требования, а именно повышение разделимости классов по критерию Фишера, физическая обоснованность производных признаков и совместимость с вектором ограничений Ψ . Обоснован гибридный подход, при котором экспертное знание о физике процессов теплопереноса формализуется в оператор Φ , а вклад каждого производного признака количественно верифицируется.

5. Выполнен отбор допустимых моделей классификации из множества методов машинного обучения на основе последовательной проверки совместимости с компонентами вектора Ψ . Исключены глубокие нейронные сети (требуют памяти на два порядка больше V_{max}), нелинейные методы опорных

векторов (не обеспечивают интерпретируемость) и методы автоматической генерации признаков (порождают пространство размерности $O(n^k)$). Отобраны три модели, удовлетворяющие всем компонентам Ψ , а именно логистическая регрессия (< 1 мс, ~ 1 КБ), случайный лес (10–20 мс, 50–150 КБ) и градиентный бустинг (15–25 мс, 80–200 КБ).

Результаты физико-математической постановки задачи обработки информации, формализация задачи классификации состояний МКС как задачи многокритериальной оптимизации с ограничениями и обоснование подхода к формированию признакового пространства получены автором лично и были частично опубликованы, в том числе в соавторстве (вклад автора более 80 %) в [20; 21; 24; 25; 28; 29].

3 Алгоритмы формирования признакового пространства и интеллектуальной поддержки принятия решений

3.1 Алгоритм формирования признакового пространства

В задачах системного анализа и интеллектуального управления сложными техническими объектами формирование признакового пространства является одним из определяющих этапов построения моделей машинного обучения. Качество признаков напрямую влияет на точность классификации, устойчивость к шуму и интерпретируемость получаемых решений. Для встраиваемых систем управления, функционирующих в условиях ограниченных вычислительных ресурсов, выбор метода формирования признаков приобретает особое значение, поскольку определяет не только качество модели, но и саму возможность ее развертывания на целевой платформе.

Анализ существующих подходов к формированию признакового пространства выявил существенное противоречие. Автоматические методы на основе технологий автоматизированного машинного обучения обеспечивают высокую масштабируемость и скорость обработки, однако требуют значительных вычислительных ресурсов и не гарантируют интерпретируемости результатов. Традиционные экспертные методы обеспечивают физическую обоснованность признаков, но не имеют формализованного регламента, что затрудняет воспроизводимость и стандартизацию процедур подготовки данных. Указанное противоречие определяет необходимость разработки алгоритма, сочетающего достоинства экспертного подхода с формализацией процедур, обеспечивающей воспроизводимость результатов.

Существующие методы формирования признакового пространства подразделяются на четыре основных класса в зависимости от степени участия эксперта и уровня автоматизации процесса. Первый класс составляют автоматические методы, основанные на алгоритмах автоматизированного поиска

оптимальных конфигураций моделей, включая программные средства автоматической генерации производных признаков и синтеза вычислительных конвейеров без участия эксперта. Достоинствами автоматических методов являются высокая масштабируемость и способность выявлять скрытые зависимости в данных, однако для них характерны высокая вычислительная стоимость, повышенный риск переобучения и ограниченная интерпретируемость. Применение автоматических методов на бортовых контроллерах криогенных систем практически невозможно вследствие аппаратных ограничений. Второй класс образуют полуавтоматические методы, работающие на основе экспертно сформированного ядра признаков и расширяющие его статистическими дескрипторами, что представляет компромисс между скоростью обработки и контролируемостью результата. Третий класс представлен ручными методами, основанными на проектировании признаков с использованием предметных знаний и технических регламентов, обеспечивающими высокую интерпретируемость и минимальные требования к вычислительным ресурсам. Четвертый класс включает гибридные методы, сочетающие экспертно сформированное ядро признаков с ограниченной автоматической генерацией дополнительных признаков. Классификация методов формирования признакового пространства с указанием их характеристик представлена на Рисунке 3.1.

Выбор алгоритма формирования признакового пространства на основе экспертных знаний для задачи интеллектуальной поддержки управления многослойной криогенной системой обусловлен совокупностью технических и методологических факторов. Ограниченные вычислительные возможности бортовых контроллеров исключают применение ресурсоемких автоматических методов. Типовые контроллеры серии STM32, используемые в системах управления криогенным оборудованием, располагают оперативной памятью объемом не более 256 КБ и не предполагают использования графических ускорителей.




Рисунок 3.1 – Классификация методов формирования признакового пространства

Требования информационной безопасности и автономности функционирования не допускают передачи больших массивов данных на внешние серверы для обработки. Необходимость обеспечения интерпретируемости решений является принципиальным требованием для систем критического применения, поскольку оператор криогенной системы должен понимать логику формирования рекомендаций. Ограниченный объем исторических данных эксплуатации (типичный объем обучающей выборки составляет 500–1000 наблюдений) также определяет выбор в пользу экспертного подхода. Сравнительный анализ подходов к формированию признаков по ключевым параметрам представлен в Таблице 3.1.

Таблица 3.1 – Сравнение методов формирования признакового пространства

Критерий	Автоматический подход	Экспертный подход
Вычислительная стоимость	Высокая (требуются графические ускорители)	Низкая (совместим со встраиваемыми контроллерами)
Масштабируемость	Высокая	Ограниченная числом экспертов
Интерпретируемость	Низкая	Высокая
Физическая обоснованность	Не гарантирована	Обеспечена экспертной верификацией
Нормативная привязка	Отсутствует	ГОСТ Р 8.736-2011, ИСО 5725-6
Объем данных для обучения	Требуется большой	Работает при ограниченном объеме

Автором предлагается алгоритм формирования признакового пространства, включающий три этапа. На первом этапе выполняется предобработка данных по

формализованному пятишаговому регламенту. На втором этапе осуществляется конструирование производных признаков на основе анализа физики криогенных процессов. На третьем этапе проводится количественная валидация вклада сконструированных признаков через аддитивную декомпозицию решений модели. Алгоритм является замкнутым, поскольку при неудовлетворительных результатах валидации предусмотрен возврат к анализу физики процесса и пересмотр конструкций. Схема алгоритма формирования признакового пространства представлена на Рисунке 3.2.



Рисунок 3.2 – Алгоритм формирования признакового пространства

В общем случае оператор конструирования производных признаков определяется как кортеж из n операторов (3.1).

$$\Phi = \langle \varphi_{m+1}, \varphi_{m+2}, \dots, \varphi_{m+n} \rangle \quad (3.1)$$

где m – размерность исходного пространства,

n – число конструируемых признаков,

φ_k – оператор вычисления k -го производного признака.

Оператор Φ преобразует исходное пространство $\mathbb{R}^m$ в расширенное $\mathbb{R}^{m+n}$, сохраняя все исходные признаки и дополняя их производными. Число n

определяется физикой исследуемого объекта и ограничениями целевой платформы.

Для многослойной криогенной системы исходное пространство имеет размерность $m = 5$. Анализ термодинамических процессов, выполненный совместно с инженерами-криогениками, выявил три физических эффекта, не отражаемых исходными признаками в явном виде. Первый эффект – пороговая потеря экранирующего слоя азота, при которой теплоприток возрастает скачкообразно. Второй – совместная характеристика давления и уровня заполнения гелиевого контура, пропорциональная запасу энергии в контуре. Третий – аналогичная характеристика для азотного контура. Двухконтурная структура системы – гелиевый контур и экранирующий азотный – задаёт верхнюю границу числа физически обоснованных конструкций, равную трём. Дополнительные взаимодействия (в частности, произведения давлений разных контуров) не имеют прямого физического смысла и не улучшают разделимость классов, что подтверждено в ходе валидации. Следовательно, для рассматриваемой задачи $n = 3$, а оператор принимает вид $\Phi = \langle \varphi_6, \varphi_7, \varphi_8 \rangle$; конкретные операторы раскрываются далее.

В исходный вектор признаков $X_{\text{raw}} \in \mathbb{R}^5$ входят пять параметров, считываемых с датчиков арматурного узла контейнера. Статус контейнера $S \in \{0, 1\}$ указывает на режим эксплуатации – транспортировка или хранение. Учёт режима необходим потому, что транспортируемые контейнеры подвержены вибрации и перепадам давления окружающей среды; отсюда требования к более частой коррекции параметров охлаждения и к повышенному вниманию к риску утечек. Уровень жидкого гелия $L_{\text{He}} \in [0, 100] \%$ с погрешностью $\pm 1 \%$ задаёт контроль основного криогенного агента – снижение этого показателя сигнализирует о возможных утечках или о недостаточной эффективности системы охлаждения. Давление гелия $P_{\text{He}} \in [0, 0,5] \text{ МПа}$ с погрешностью $\pm 0,5 \%$ отражает термодинамическое состояние гелиевого контура; колебания этого параметра могут быть вызваны изменениями теплового режима либо нарушением герметичности. Уровень жидкого азота $L_{\text{N}_2} \in [0, 100] \%$ с погрешностью $\pm 1 \%$

характеризует состояние экранирующего слоя – поддержание оптимального уровня решает задачу изоляции внутреннего сосуда от внешних температурных воздействий. Давление азота $P_{N_2} \in [0, 1,0]$ МПа с погрешностью $\pm 0,5$ % отражает термодинамическое состояние экранирующего слоя; совместный анализ уровня и давления даёт оценку состояния азотного контура как единого целого. Сформированный набор из пяти признаков охватывает все ключевые параметры двухконтурной криогенной системы и согласуется с составом измерительных каналов типового бортового контроллера.

Предобработка данных выполнена по формализованному пятишаговому регламенту; каждый шаг регламента опирается на нормативные документы и экспертные знания о физике криогенных процессов.

Схема пятишагового регламента предобработки представлена на Рисунке 3.3.




Рисунок 3.3 – Пятишаговый регламент предобработки данных

На первом шаге выполняется удаление технических дубликатов. Записи с совпадением всех пяти параметров и временной меткой в пределах 1 минуты считаются дубликатами, возникающими при повторной передаче вследствие сбоя подтверждения приема, при этом сохраняется первая запись, а остальные удаляются. Нормативное обоснование данной процедуры содержится в ГОСТ Р 8.736-2011 «Государственная система обеспечения единства измерений. Измерения прямые многократные. Методы обработки результатов измерений». На

втором шаге удаляются записи периодов технического обслуживания, поскольку во время обслуживания контейнер вскрывают, меняют уплотнения, проверяют вакуум, вследствие чего датчики показывают нерабочие значения, и исключаются все записи за период ± 24 часа от даты обслуживания по журналу. На третьем шаге удаляются записи с отказами датчиков, для чего применяются критерии отсева по физическому диапазону (уровень гелия или азота вне $[0,100]$ %, давление гелия отрицательное или выше предела безопасности контейнера ~ 150 МПа), критерий зависания (более 10 подряд идентичных значений любого параметра при статусе «в пути»), а также метод межквартильного размаха, при котором значения за пределами $[Q_1 - 1,5 \cdot IQR; Q_3 + 1,5 \cdot IQR]$ отсекаются в соответствии с ИСО 5725-6:2002. На четвертом шаге удаляются записи переходных режимов после долива азота, когда система выходит на стационарный режим за 30–60 минут, и записи в пределах 2 часов после зафиксированного долива исключаются как содержащие аномальные соотношения параметров. На пятом шаге выполняется экспертная верификация оставшихся записей на непротиворечивость, например проверяется, что при нулевом уровне азота давление азота близко к нулю, а записи с нелогичными комбинациями параметров удаляются с документированием причины. Результаты предобработки данных по каждому шагу регламента представлены в Таблице 3.2.

Таблица 3.2 – Результаты предобработки данных по шагам

Шаг	Описание	Удалено записей	Осталось	Доля от исходных
Исходные данные	–	–	1500	100 %
1	Удаление технических дубликатов	120	1380	92 %
2	Удаление записей периодов ТО	180	1200	80 %
3	Удаление записей с отказами датчиков	250	950	63 %
4	Удаление записей переходных режимов	150	800	53 %
5	Экспертная верификация	70	730	49 %

Таким образом, из 1500 исходных записей сформирован набор из 730 наблюдений (49 % от исходного объема), пригодных для обучения модели. Потеря 51 % данных обусловлена жесткими требованиями к качеству обучающей выборки, поскольку каждая удаленная запись соответствует физически некорректному или нерепрезентативному состоянию системы, включение которого в обучающую выборку снизило бы надежность модели.

На втором этапе алгоритма выполняется конструирование производных признаков. Исходное пространство R^5 не обеспечивает достаточной разделимости классов для простых моделей, пригодных к развертыванию на встраиваемых системах. Автоматические методы генерации признаков требуют вычислительных ресурсов, несовместимых с ограничениями контроллера STM32. Автором предлагается конструирование производных признаков на основе анализа физики криогенных процессов, что обеспечивает физическую обоснованность и интерпретируемость каждого нового признака. Связь между физическими закономерностями криогенных процессов и формулами конструирования признаков представлена на Рисунке 3.4.




Рисунок 3.4 – Физическое обоснование производных признаков

Первый конструктивный признак x_6 представляет собой бинарный индикатор критического состояния азотного экрана и определяется как (3.2).

$$x_6 = I(L_{N_2} \leq \delta) \quad (3.2)$$

где $I(\cdot)$ – функция-индикатор, принимающая значение 1 при выполнении условия и 0 в противном случае,

δ – пороговое значение уровня азота (приблизительно 10–15 % от номинального уровня), при котором экранирующий слой утрачивает защитные свойства.

Физический смысл данного признака связан с нелинейным пороговым эффектом потери азотного экрана. Экранирующий слой жидкого азота утрачивает защитные свойства не плавно, а скачкообразно – в момент достижения критического уровня. При снижении уровня жидкого азота ниже критического порога оголяется верхняя часть азотного экрана; радиационный теплоприток к гелиевому контуру в этот момент скачкообразно возрастает примерно в 250 раз. В

многослойной изоляционной системе криогенного контейнера азотный экран выполняет роль радиационного щита – он перехватывает тепловой поток, идущий от внешней оболочки к внутреннему сосуду с жидким гелием. До тех пор, пока экран заполнен выше критического уровня, эффективная температура излучающей поверхности держится вблизи 77 К (температура кипения азота при атмосферном давлении). С потерей экрана излучающая поверхность приобретает температуру внешней оболочки (порядка 300 К); по закону Стефана–Больцмана ($q \sim T^4$) радиационный теплоприток возрастает в $(300/77)^4 \approx 230$ раз. За счёт этого признака модель разграничивает штатное и критическое состояния экранирующего контура, получая чёткую границу между безопасным режимом эксплуатации и режимом, требующим немедленного вмешательства.

Второй конструктивный признак x_7 – интегральный параметр гелиевого контура – рассчитывается по формуле (3.3).

$$x_7 = \sqrt{P_{He} \cdot L_{He}}. \quad (3.3)$$

Физический смысл этого признака – характеристика термодинамического состояния двухфазной системы «жидкость–пар» в гелиевом контуре. Произведение давления на уровень заполнения пропорционально запасу энергии в контуре: при $L = V/V_{max} \cdot (V_{max} - \text{полный объём сосуда})$ и фиксированной геометрии величина $P \cdot L$ пропорциональна $P \cdot V$, то есть характеризует термодинамическую энергию газовой фазы. Давление P , в свою очередь, отражает равновесное состояние двухфазной системы.

Уровень заполнения L_{He} в криогенном контейнере пропорционален объёму жидкой фазы, а давление P_{He} отражает равновесное состояние двухфазной системы. Произведение $P_{He} \cdot L_{He}$ образует интегральную характеристику, в которой учтено совместное влияние обоих параметров на термодинамическое состояние контура. Одновременное падение давления и уровня говорит об ускоренном испарении гелия и потере криогенного продукта; рост давления при стабильном уровне – повод подозревать нарушение теплоизоляции. Извлечение квадратного корня

нужно по двум причинам: чтобы согласовать масштаб с исходными признаками и чтобы ослабить влияние выбросов при экстремальных значениях давления или уровня.

Третий конструктивный признак x_8 – интегральный параметр азотного контура – вычисляется аналогично (3.4):

$$x_8 = \sqrt{P_{N_2} \cdot L_{N_2}}. \quad (3.4)$$

В этом признаке собрана информация о состоянии экранирующего слоя; его введение улучшает наблюдаемость азотного контура, что особенно важно для безопасности эксплуатации системы. Физическое обоснование здесь то же, что и для признака x_7 , однако применительно к азотному контуру интегральный параметр обретает дополнительный смысл. Азотный контур выполняет защитную функцию по отношению к гелиевому, и деградация его состояния – одновременное снижение давления и уровня – служит предвестником критической ситуации с потерей гелия. Признак x_8 позволяет уловить такую деградацию на ранней стадии: когда уровень и давление по отдельности ещё в допустимых пределах, а их совместное снижение уже указывает на нарушение теплового баланса экранирующего слоя.

Оператор $\Phi: R^5 \rightarrow R^8$ сохраняет пять исходных параметров и добавляет три сконструированных. В итоге расширенный вектор признаков приобретает вид (3.5).

$$X' = \Phi(X_{raw}) = (S, L_{He}, P_{He}, L_{N_2}, P_{N_2}, x_6, x_7, x_8). \quad (3.5)$$

Каждый компонент оператора $\Phi = \langle \varphi_6, \varphi_7, \varphi_8 \rangle$ имеет явное физическое обоснование и минимальную вычислительную сложность. Оператор φ_6 фиксирует пороговый эффект потери экранирующего слоя азота и требует одной операции сравнения ($O(1)$). Оператор φ_7 характеризует запас энергии гелиевого контура и требует одного умножения и извлечения квадратного корня ($O(1)$). Оператор φ_8 аналогичным образом описывает состояние экранирующего слоя ($O(1)$). Общее

время вычисления оператора Φ не превышает нескольких микросекунд, что пренебрежимо мало по сравнению с периодом опроса датчиков (2 часа) и делает оператор пригодным для выполнения на бортовом контроллере STM32 в реальном времени. Характеристики производных признаков обобщены в Таблице 3.3.

Таблица 3.3 – Производные признаки

Признак	Обозначение	Формула	Физическое основание	Вычислительная сложность
Индикатор критического уровня N_2	x_6	$I(L_{N_2} \leq \delta)$	Пороговый эффект потери азотного экрана (теплоприток $\times 250$)	$O(1)$, одно сравнение
Интегральный параметр гелия	x_7	$\sqrt{P_{He} \cdot L_{He}}$	Характеристика термодинамического состояния ($PV = nRT$)	$O(1)$, умножение и корень
Интегральный параметр азота	x_8	$\sqrt{P_{N_2} \cdot L_{N_2}}$	Агрегированное состояние экранирующего слоя	$O(1)$, умножение и корень

На третьем этапе алгоритма проводится количественная валидация вклада сконструированных признаков. Для объективной оценки обоснованности выбранных конструкций необходимо количественно определить вклад каждого признака в решения модели. С этой целью применена аддитивная декомпозиция на основе метода SHAP [95], позволяющая для каждого наблюдения разложить решение модели на вклады отдельных признаков. Для каждого наблюдения решение модели $f(X)$ представляется в виде (3.6).

$$f(X) = \varphi_0 + \sum_{j=1}^M \varphi_j \quad (3.6)$$

где φ_0 – базовое значение модели, соответствующее среднему предсказанию по обучающей выборке,

φ_j – вклад j -го признака в конкретное решение,

$M = 8$ – число признаков в расширенном пространстве.

Значение $\varphi_j > 0$ указывает на то, что j -й признак повышает вероятность отнесения наблюдения к классу 1 (необходимость долива), а $\varphi_j < 0$ – снижает ее.

По обучающей выборке вычислены средние абсолютные вклады каждого признака $|\overline{\varphi_j}|$, характеризующие среднюю значимость признака для решений модели. Результаты представлены в Таблице 3.4.

Таблица 3.4 – Вклад признаков в решения модели (средние абсолютные значения)

Признак	Обозначение	Тип	Средний $ \varphi_j $	Доля от суммы	Ранг
Интегральный параметр N_2	x_8	Сконструированный	0,420	54 %	1
Интегральный параметр He	x_7	Сконструированный	0,280	36 %	2
Уровень азота	L_{N_2}	Исходный	0,120	–	3
Индикатор критического уровня	x_6	Сконструированный	0,080	10 %	4
Давление азота	P_{N_2}	Исходный	0,050	–	5
Уровень гелия	L_{He}	Исходный	0,030	–	6
Давление гелия	P_{He}	Исходный	0,015	–	7
Статус контейнера	S	Исходный	0,005	–	8
Итого сконструированные	$x_6 + x_7 + x_8$		0,780	78 %	

Три производных признака обеспечивают 78 % суммарного вклада в решения модели. Два верхних по значимости признака – интегральные параметры азотного (x_8 , 54 %) и гелиевого (x_7 , 36 %) контуров – оба являются сконструированными. Это количественно подтверждает обоснованность выбранных конструкций и эффективность оператора Φ . Столбчатая диаграмма распределения вкладов признаков представлена на Рисунке 3.5.




Рисунок 3.5 – Вклад признаков в решения модели

Результаты валидации свидетельствуют о том, что переход от исходного пространства R^5 к расширенному R^8 существенно улучшает информативность признакового пространства. Интегральные параметры x_7 и x_8 , агрегирующие совместное влияние давления и уровня заполнения контуров, оказались более информативными, чем отдельные параметры давления и уровня, что согласуется с физикой процесса, поскольку именно произведение $P \cdot L$ пропорционально запасу энергии в контуре и несет информацию, не выводимую из отдельных параметров. Бинарный индикатор x_6 , при всём относительно скромном среднем вкладе (10 %), приобретает критическую роль в околопороговых значениях уровня азота – именно он чётко разграничивает штатный и аварийный режимы.

Насколько лучше классы разделяются при переходе от исходного пространства R^5 к расширенному R^8 , наглядно показывает Рисунок 3.6. Если же валидация даст плохой результат – суммарный вклад производных признаков окажется ниже порога, – алгоритм отправляет обратно: к разбору физики процесса и пересмотру конструкций. Так и замыкается цикл формирования признакового

пространства. У нас валидация дала 78 %, что заметно выше порога, – выбранный набор конструкций себя оправдал.




Рисунок 3.6 – Распределение классов в R^5 и R^8

На формальном уровне алгоритм формирования признакового пространства определяется как композиция трёх этапов (3.7):

$$\Phi_{full} = V \circ C \circ P. \quad (3.7)$$

где P – оператор предобработки (пятишаговый регламент, $R^5 \rightarrow R^5$),

C – оператор конструирования производных признаков ($R^5 \rightarrow R^8$),

V – оператор валидации вклада (проверка критерия $\sum_{j=6}^8 \overline{|\varphi_j|} / \sum_{j=1}^8 \overline{|\varphi_j|} \geq \theta$, где θ – пороговое значение).

При невыполнении критерия валидации алгоритм возвращает к этапу C – и так до тех пор, пока критерий не будет удовлетворён.

Предложенный алгоритм формирования признакового пространства расширяет исходное R^5 до R^8 , причём расширение опирается на физически обоснованные конструкции. Регламент предобработки в пять шагов привязан к нормативным документам – ГОСТ Р 8.736-2011 и ИСО 5725-6:2002 – и обеспечивает воспроизводимость очистки данных. Производные признаки строятся на термодинамических соотношениях и пороговых эффектах; именно

поэтому каждый новый признак удаётся физически интерпретировать. Количественную проверку вклада провели через аддитивную декомпозицию: три производных признака дают 78 % суммарного вклада в решения модели – этого достаточно, чтобы перейти к построению классификатора в пространстве R^8 . От традиционных подходов к формированию признаков предложенный алгоритм отличается одним: цикл «физика – конструирование – валидация» у него замкнут, и эта замкнутость и создаёт обратную связь между качеством модели и структурой признакового пространства.

3.2 Алгоритм интеллектуальной поддержки принятия решений

Автором предлагается алгоритм интеллектуальной поддержки принятия решений, в составе которого две составляющие. Первая составляющая – модель классификации состояний на расширенном признаковом пространстве R^8 , оптимизированная с учётом дисбаланса классов и асимметрии последствий ошибок. Вторая составляющая – алгоритм представления результатов оператору, обеспечивающий формирование интерпретируемой рекомендации с указанием факторов, определивших решение модели. Общая схема алгоритма интеллектуальной поддержки принятия решений представлена на Рисунке 3.7.




Рисунок 3.7 – Алгоритм интеллектуальной поддержки принятия решений


Модель классификации строится на расширенном признаковом пространстве R^8 , полученном в результате применения оператора Φ . При построении модели учтены две особенности данных, существенно влияющие на процедуру обучения и валидации.

Первая особенность – дисбаланс классов. Из 730 наблюдений очищенной выборки 688 относятся к классу 0 (штатное состояние) и 42 к классу 1 (необходимость долива жидкого азота), что дает соотношение 16,4 к 1. При таком дисбалансе модель, предсказывающая всегда класс 0, достигает точности 94,2 %, однако полностью пропускает все критические состояния. Для компенсации дисбаланса применено взвешивание наблюдений обратно пропорционально частоте класса, что вынуждает модель уделять равное внимание обоим классам при оптимизации функции потерь.

Вторая особенность – асимметрия последствий ошибок. Пропуск критического состояния (ложноотрицательная ошибка) оборачивается потерей криогенного продукта стоимостью порядка нескольких миллионов рублей; ложная же тревога (ложноположительная ошибка) влечёт за собой лишь внеплановую проверку со стоимостью на два порядка ниже. Отношение стоимостей ошибок – $\alpha/\beta \approx 100$, и именно оно диктует приоритет полноты над точностью. Указанная асимметрия учтена за счёт настройки порога принятия решения и выбора целевой метрики оптимизации, в которой приоритет отдан полноте обнаружения критических состояний.

Оптимизация гиперпараметров проведена в режиме стратифицированной пятикратной кросс-валидации. Выбор $k = 5$ продиктован спецификой выборки. При объёме 730 наблюдений и дисбалансе 16,4 к 1 в каждом из пяти фолдов оказывается примерно 8–9 наблюдений класса 1 – этого хватает для устойчивой оценки полноты. Если же взять $k = 10$, в каждом фолде остаётся всего 4 наблюдения миноритарного класса, а такие оценки становятся нестабильными. При схеме «один против всех» оценка дисперсии затруднена. Таким образом, значение $k = 5$

обеспечивает баланс между смещением и дисперсией оценки. Схема стратифицированной кросс-валидации представлена на Рисунке 3.8.



Стратификация: соотношение классов 17,6:1 сохраняется в каждом фолде

Рисунок 3.8 – Схема стратифицированной пятикратной кросс-валидации

На каждой из пяти итераций кросс-валидации четыре пятых данных используются для обучения, одна пятая – для валидации. Внутри обучающей части выполняется полный перебор по сетке гиперпараметров с целевой метрикой F_1 для миноритарного класса. Метрика F_1 выбрана как целевая, поскольку она учитывает и точность, и полноту, штрафую модели с перекосом в одну сторону. Пространство поиска гиперпараметров для рассматриваемых моделей представлено в Таблице 3.5.

Таблица 3.5 – Пространство поиска гиперпараметров

Параметр	Случайный лес	Градиентный бустинг
Число деревьев / итераций	{100, 200, 300, 500}	{100, 200, 300}
Максимальная глубина	{5, 7, 9, 12, без ограничений}	{2, 3, 4, 5}
Мин. число образцов в листе	{1, 2, 5}	{1, 2, 5}

Параметр	Случайный лес	Градиентный бустинг
Макс. число признаков	$\{\sqrt{M}, \log_2 M, 0,5M\}$	–
Скорость обучения	–	$\{0,01; 0,05; 0,1; 0,2\}$

Результаты сравнения моделей на расширенном пространстве R^8 с оптимизированными гиперпараметрами представлены в Таблице 3.6. Случайный лес и градиентный бустинг достигают одинаковой средней $F_1 = 0,925$ при низкой дисперсии ($\sigma = 0,021$ и $\sigma = 0,024$ соответственно). Логистическая регрессия существенно уступает ансамблевым методам ($F_1 = 0,653$) и при этом менее стабильна ($\sigma = 0,087$).

Таблица 3.6 – Сравнение моделей на расширенном пространстве R^8

Модель	F_1 среднее	$\sigma(F_1)$	Точность среднее	Полнота среднее
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

Стандартное отклонение $\sigma(F_1) = 0,021$ для случайного леса указывает на высокую устойчивость результатов. Все пять фолдов дают F_1 в узком диапазоне от 0,900 до 0,950 без провалов и выбросов. Коэффициент вариации $CV = \sigma/\mu = 0,021/0,925 = 2,3 \%$, что значительно ниже порога 5 %, принятого в качестве показателя хорошей воспроизводимости результатов.

При равной F_1 случайного леса и градиентного бустинга выбор итоговой модели определяется принципом парсимонии. Случайный лес состоит из независимых деревьев, обучаемых параллельно, тогда как градиентный бустинг строит деревья последовательно, и каждое следующее дерево корректирует ошибки предыдущего. Независимость деревьев в случайном лесе обеспечивает большую робастность к выбросам и более простую интерпретацию через аддитивную декомпозицию. При одинаковых метриках качества предпочтение

отдается более простой модели, что согласуется с принципом бритвы Оккама. Объем памяти модели случайного леса на контроллере STM32 составляет приблизительно 80–120 КБ (200 деревьев, средняя глубина обхода 6–7 уровней, ≈ 100 узлов на дерево, 4 байта на узел), время вывода не превышает 20 мс, что укладывается в ограничение 50 мс с запасом 2,5 раза.

Статистическая значимость различий между моделями подтверждена непараметрическим критерием Уилкоксона для связанных выборок. Выбор непараметрического критерия обусловлен тем, что при пяти наблюдениях (значения F_1 на каждом фолде) проверка нормальности распределения затруднительна. Для каждого фолда i вычислена разность $d_i = F_1^{\text{лес}}(i) - F_1^{\text{лог.рег.}}(i)$. Критерий проверяет нулевую гипотезу H_0 о равенстве медианы разностей нулю (модели эквивалентны) против альтернативной гипотезы H_1 о неравенстве. Результаты представлены в Таблице 3.7.

Таблица 3.7 – Статистическая значимость различий между моделями

Сравнение	Статистика W	p-значение	Вывод
Случайный лес – логистическая регрессия	15	0,031	Значимо ($p < 0,05$)
Случайный лес – градиентный бустинг	–	$> 0,5$	Незначимо

Все пять разностей d_i для пары «случайный лес – логистическая регрессия» положительны (от +0,196 до +0,338), что дает максимальное значение статистики $W = 15 = n(n + 1)/2$ при $n = 5$ и $p = 0,031 < 0,05$. Гипотеза об эквивалентности моделей отклоняется. Различие между случайным лесом и градиентным бустингом статистически незначимо ($p > 0,5$), что свидетельствует о достижении предела качества классификации ансамблевыми методами на данной выборке.

Вторая составляющая алгоритма обеспечивает формирование интерпретируемой рекомендации для оператора. Полная аддитивная декомпозиция (формула 3.6) на бортовом контроллере невозможна, поскольку требует перебора 2^M коалиций признаков, что при $M = 8$ составляет 256 вычислений для каждого

наблюдения. При периоде опроса 2 часа – это допустимо, однако для контроллера STM32 с ограниченной памятью хранение полной таблицы вкладов создает избыточную нагрузку. Автором предлагается алгоритм упрощенного представления, адаптированный к ресурсам встраиваемого контроллера. Схема алгоритма представлена на Рисунке 3.9.




Рисунок 3.9 – Алгоритм представления результатов оператору

Контроллер определяет степень отклонения каждого из восьми параметров расширенного пространства от эталонного диапазона, рассчитанного по данным штатных рейсов. Для каждого параметра x_j эталонный диапазон задается интервалом $[\mu_j - 2\sigma_j, \mu_j + 2\sigma_j]$, где μ_j и σ_j – среднее и стандартное отклонение по наблюдениям класса 0 обучающей выборки. Степень отклонения вычисляется как (3.8).

$$\Delta_j = \frac{|x_j - \mu_j|}{\sigma_j}. \quad (3.8)$$

Параметры ранжируются по величине отклонения Δ_j в порядке убывания. По трём параметрам с наибольшим отклонением строится текстовое объяснение – по шаблону, увязывающему отклонения с физическим смыслом. Так, при высоком значении Δ_8 (интегральный параметр азотного контура) шаблон формирует пояснение: «основной фактор – снижение интегрального параметра азотного контура, что указывает на деградацию экранирующего слоя».

Рекомендация, выводимая на планшет оператора, содержит три компоненты. Первая – результат классификации $Y \in \{0, 1\}$. Вторая – степень уверенности модели $P(Y = 1 | X)$; по ней оператор оценивает надёжность рекомендации. Третья – обоснование решения с указанием ведущих факторов и их отклонений от нормы. При такой структуре рекомендации оператор переходит от субъективной оценки показаний отдельных датчиков к верифицируемому решению, которое опирается на совместный анализ всех параметров расширенного пространства.

Алгоритм упрощённого представления требует $O(M \log M)$ операций – это сортировка M отклонений – и хранения $2M$ параметров (μ_j и σ_j); при $M = 8$ объём памяти – 64 байта (float32). Это пренебрежимо мало по сравнению с объёмом памяти самой модели (80–120 КБ) и не создает дополнительных ограничений при развертывании на контроллере STM32.

Разработанный алгоритм интеллектуальной поддержки принятия решений объединяет модель классификации состояний на расширенном признаковом пространстве R^8 с алгоритмом формирования интерпретируемой рекомендации. Модель классификации (случайный лес с оптимизированными гиперпараметрами) достигает $F_1 = 0,925 \pm 0,021$ на пятикратной стратифицированной кросс-валидации, при этом статистическая значимость преимущества над линейной моделью подтверждена критерием Уилкоксона ($W = 15$, $p = 0,031$). Алгоритм представления результатов обеспечивает формирование обоснования решения, содержащего результат классификации, степень уверенности и перечень ведущих

факторов с их отклонениями от нормы, что позволяет оператору принимать верифицируемые решения на основе объективных данных.

3.3 Функциональная модель системы поддержки принятия решений и алгоритм адаптации модели

Разработанные в предыдущих разделах алгоритм формирования признакового пространства и алгоритм интеллектуальной поддержки принятия решений требуют объединения в целостную систему, способную функционировать в условиях промышленной эксплуатации. Автором предлагается функциональная модель системы поддержки принятия решений (далее СППР), описывающая технологический процесс обработки информации в двух режимах работы, а также алгоритм адаптации модели на эксплуатационных данных.

Существующие системы мониторинга криогенного оборудования реализуют один из двух подходов. Первый подход предполагает полностью автоматическое регулирование, при котором управляющее воздействие формируется без участия оператора. Такие системы автоматического регулирования эффективны в стационарных условиях, однако при изменении характеристик объекта, связанном с деградацией многослойно-вакуумной теплоизоляции, требуют перенастройки параметров регулятора. Второй подход основан на ручном контроле, при котором оператор принимает решения на основе показаний приборов и собственного опыта. Этот подход гибок, но зависит от квалификации конкретного оператора и не обеспечивает воспроизводимости решений.

Автором предлагается третий подход, при котором модель машинного обучения формирует рекомендацию с обоснованием, а оператор принимает окончательное решение. Такая супервизорная архитектура сочетает объективность алгоритмической обработки данных с возможностью учёта контекстных факторов, недоступных модели. Сравнение подходов представлено на Рисунке 3.10.




Рисунок 3.10 – Сравнение подходов к управлению доливом криогенного продукта

Функциональная модель СППР формально определяется как кортеж (3.9).

$$\text{СППР} = \langle L_{\text{sensor}}, L_{\text{controller}}, L_{\text{ble}}, L_{\text{tablet}} \rangle. \quad (3.9)$$

где L_{sensor} – сенсорная подсистема, формирующая вектор измерений $X_{\text{raw}} \in R^5$;

$L_{\text{controller}}$ – бортовой контроллер, выполняющий предобработку, преобразование признакового пространства $\Phi: R^5 \rightarrow R^8$, классификацию и формирование рекомендации;

L_{ble} – канал беспроводной связи с шифрованием;

L_{tablet} – планшет оператора с интерфейсом представления рекомендаций и буфером накопления данных.

Функциональная модель предусматривает два режима работы, отличающихся периодичностью и характером обработки информации. Общая схема представлена на Рисунке 3.11.




Рисунок 3.11 – Функциональная модель системы поддержки принятия решений

В штатном режиме период опроса составляет 2 часа, что определяется инерционностью теплофизических процессов в криогенном контейнере. Информация последовательно проходит четыре стадии обработки.

На первой стадии сенсорная подсистема L_{sensor} формирует вектор измерений $X_{\text{raw}} = (P_{\text{He}}, L_{\text{He}}, P_{\text{N}_2}, L_{\text{N}_2}, S)^T$, где $P_{\text{He}}, L_{\text{He}}$ – давление и уровень гелия, $P_{\text{N}_2}, L_{\text{N}_2}$ – давление и уровень азота, S – длительность текущего рейса.

На второй стадии контроллер $L_{\text{controller}}$ выполняет предобработку данных, применяет оператор Φ для расширения признакового пространства до $\mathbb{R}^8$, производит классификацию состояния и формирует рекомендацию с указанием ведущих факторов.

На третьей стадии результат передается через канал L_{ble} на планшет оператора.

На четвертой стадии оператор получает рекомендацию, включающую результат классификации $\hat{Y}$, степень уверенности $P(Y = 1|X)$ и обоснование решения, и принимает окончательное решение о необходимости долива.

Результаты каждого цикла обработки буферизуются в памяти планшета для последующего использования при адаптации модели. Буфер накапливает как вектора измерений, так и решения, принятые оператором, что создает основу для обратной связи.

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

Распределение функций между уровнями системы представлено в Таблице 3.8.

Таблица 3.8 – Распределение функций между уровнями СППР

Уровень	Компонент	Функции	Ограничения
L_{sensor}	Датчики арматурного узла	Формирование $X_{\text{raw}} \in R^5$	Период опроса 2 ч
$L_{\text{controller}}$	Контроллер STM32	Предобработка, Φ , классификация, формирование рекомендации	Память ≤ 256 КБ, время вывода ≤ 50 мс
L_{ble}	Канал связи	Передача данных, шифрование	Шифрование по стандарту
L_{tablet}	Планшет оператора	Отображение рекомендации, буферизация данных	Емкость буфера 1100–2200 записей

Функциональная модель СППР реализована в четырёхуровневой архитектуре развертывания, схема которой представлена на Рисунке 3.12. Каждый уровень архитектуры выполняет строго определенный набор функций, что обеспечивает модульность системы и возможность независимого обновления компонентов.

Первый уровень архитектуры образуют датчики арматурного узла контейнера-цистерны, формирующие пять исходных параметров.

Второй уровень составляет бортовой контроллер STM32, на котором выполняются все вычислительные операции.




Рисунок 3.12 – Четырёхуровневая архитектура развертывания СППР

Вектор ограничений контроллера Ψ определяет требования к развертываемой модели (3.10).

$$\Psi = (\psi_{mem}, \psi_{time}, \psi_{recall}) = (256 \text{ КБ}, 50 \text{ мс}, 0,95). \quad (3.10)$$

Модель случайного леса, отобранная по итогам сравнительного анализа, занимает 80–120 КБ оперативной памяти (200 деревьев; средняя глубина обхода – 6–7 уровней; около 100 узлов на дерево; 4 байта на узел) – под остальные функции контроллера остаётся 136–176 КБ. Время вывода не превышает 20 мс: это укладывается в ограничение 50 мс с запасом в 2,5 раза. Полнота обнаружения критических состояний при стандартном пороге 0,5 равна 0,876. Снижение порога до 0,35 поднимает полноту до 0,95 (Ψ_3); при этом точность падает до 0,72, а $F1 = 0,82$ – что допустимо при соотношении стоимостей ошибок 100 : 1.

Третий уровень – канал беспроводной связи; в нём обмен данными реализован через три характеристики. Первая характеристика передаёт текущее состояние контейнера с результатом классификации и обоснованием. Вторая характеристика даёт доступ к истории измерений. Третья характеристика

используется для конфигурирования параметров контроллера и загрузки обновленных моделей. Шифрование данных осуществляется по стандарту, что обеспечивает защиту передаваемой информации.

Четвертый уровень составляет планшет оператора, выполняющий две функции. Первая функция – отображение рекомендации системы в наглядной форме, включающей результат классификации, степень уверенности и перечень ведущих факторов с их отклонениями от нормы. Вторая функция – буферизация данных телеметрии и решений оператора в течение межсервисного интервала. Емкость буфера при периоде опроса 2 часа составляет 1100–2200 записей за 3–6 месяцев, что достаточно для формирования репрезентативной выборки при адаптации.

Архитектура обеспечивает автономность контроллера при потере связи с планшетом. Классификация и формирование рекомендации выполняются на контроллере независимо от состояния канала связи. При восстановлении соединения накопленные данные передаются на планшет пакетно.

Концептуальные основы адаптивной системы интеллектуальной поддержки принятия решений для управления многослойной криогенной системой, обеспечивающей обновление модели классификации в процессе эксплуатации, изложены автором в [20]. На основе этих положений автором предлагается алгоритм адаптации модели на эксплуатационных данных, описывающий процедуру обновления модели классификации с привязкой к плановому техническому обслуживанию. Необходимость адаптации обусловлена двумя факторами. Во-первых, многослойно-вакуумная теплоизоляция постепенно деградирует, что изменяет статистические характеристики контролируемых параметров. Во-вторых, парк контейнеров-цистерн неоднороден по возрасту и условиям эксплуатации, что требует учёта индивидуальных особенностей при длительном мониторинге.

Алгоритм адаптации формально определяется как кортеж (3.11).

$$A_{\text{adapt}} = \langle \tau, C, \lambda, T, V, D, \psi \rangle, \quad (3.11)$$

где τ – предикат инициации, срабатывающий при техническом обслуживании;

S – оператор сбора данных из буфера планшета и журнала доливов;

λ – оператор автоматической разметки по правилу шести часов;

T – оператор обучения на скользящем окне 18 месяцев;

V – предикат двойной валидации по критерию (3.13);

D – оператор развертывания на контроллере;

ψ – предикат верификации на 10 контрольных записях.

Каждый элемент кортежа соответствует одному шагу процедуры адаптации.

Общая схема алгоритма представлена на Рисунке 3.13.




Рисунок 3.13 – Алгоритм адаптации модели на эксплуатационных данных

Первый шаг – инициация процедуры адаптации. Привязка к плановому техническому обслуживанию обусловлена тем, что в этот момент доступны как данные телеметрии с планшета, так и верифицированные записи о фактических доливах из учётной системы предприятия. Периодичность обслуживания

составляет 3–6 месяцев, что определяет минимальный интервал между циклами адаптации.

Второй шаг – сбор данных. Данные телеметрии, накопленные в буфере планшета за период эксплуатации, выгружаются на рабочую станцию. Параллельно из учётной системы извлекается журнал фактических доливов азота с указанием даты и времени каждого события. Объем выгружаемых данных составляет 1100–2200 записей за один межсервисный интервал.

Третий шаг – автоматическая разметка. Разметка выполняется по правилу временного горизонта (3.12).

$$y_i = \begin{cases} 1, & \text{если долив зафиксирован в течение } \tau_h \text{ часов после наблюдения } i, \\ 0, & \text{иначе,} \end{cases} \quad (3.12)$$

где $\tau_h = 6$ часов.

Значение параметра τ_h определено из анализа технологических регламентов обслуживания. Автоматическая разметка устраняет необходимость экспертной оценки каждого наблюдения и обеспечивает воспроизводимость процедуры.

Четвертый шаг – формирование обучающей выборки и переобучение модели (train). Обучающая выборка формируется по принципу скользящего окна длиной 18 месяцев, что соответствует двум полным сезонным циклам. Выбор ширины окна обусловлен двумя соображениями. С одной стороны, окно должно быть достаточно широким для охвата сезонной вариативности параметров, зависящих от температуры окружающей среды. С другой стороны, включение слишком старых данных нежелательно, поскольку характеристики теплоизоляции изменяются со временем вследствие деградации. Схема скользящего окна представлена на Рисунке 3.14.




Рисунок 3.14 – Схема скользящего окна при адаптации модели

Модель переобучается на сформированной выборке с теми же гиперпараметрами, которые были определены при первоначальной оптимизации. Повторная оптимизация гиперпараметров при каждом цикле адаптации нецелесообразна, поскольку оптимальные значения определяются структурой задачи, а не конкретной выборкой.

Пятый шаг – валидация обновленной модели. Автором предлагается двойной критерий принятия обновления (3.13).

$$F_1(f_{\text{new}}) \geq F_1(f_{\text{old}}) - 0,05 \wedge \text{Recall}(f_{\text{new}}) \geq 0,95, \quad (3.13)$$

где F_1 – взвешенная метрика точности и полноты классификации;

f_{new} – обновленная модель, обученная на скользящем окне $W = 18$ мес.;

f_{old} – текущая модель, развернутая на контроллере;

Recall – полнота обнаружения класса 1 (потребность в доливе).

Первое условие не позволяет обновлённой модели уступить текущей по совокупному качеству более чем на допустимую величину δ . Второе условие задаёт жёсткое ограничение снизу – на полноту обнаружения критических состояний. Использование двух условий одновременно обусловлено асимметрией

последствий ошибок ($\alpha/\beta \approx 100$), рост F_1 за счёт точности при одновременной просадке полноты неприемлем. Мягкий допуск $\delta = 0,05$ вводится с учётом статистической вариативности оценок при ограниченном объёме выборки.

Шестой шаг – развёртывание обновлённой модели. При выполнении обоих условий двойного критерия модель сериализуется в формат, совместимый с контроллером STM32. Загрузка на контроллер выполняется по каналу связи, целостность данных подтверждается контрольной суммой (32-битный циклический код). Такая верификация исключает попадание повреждённой модели на бортовое оборудование.

Седьмой шаг – контрольный прогон. Обновлённая модель классифицирует 10 последних буферизованных записей; результаты сопоставляются с результатами предыдущей версии. Совпадение результатов означает корректность развёртывания. При расхождениях, превышающих допустимый порог, производится откат к предыдущей версии модели.

Невыполнение хотя бы одного условия двойного критерия на этапе валидации оставляет текущую модель без изменений. Этим обеспечивается монотонность качества системы в процессе эксплуатации.

Параметры алгоритма адаптации сведены в Таблице 3.9.

Таблица 3.9 – Параметры алгоритма адаптации

Параметр	Обозначение	Значение	Обоснование
Период адаптации	T_{adapt}	3–6 мес.	Привязка к плановому ТО
Временной горизонт разметки	τ_h	6 ч	Технологический регламент
Ширина скользящего окна	W	18 мес.	Два сезонных цикла
Допуск по F_1	δ	0,05	Статистическая вариативность
Порог полноты	τ	0,95	Асимметрия последствий ошибок
Объём контрольного прогона	n_{verify}	10 записей	Последние буферизованные данные

Функциональная модель СППР совместно с алгоритмом адаптации образуют замкнутый цикл обработки информации с обратной связью. В штатном режиме рекомендации формируются по текущим данным с периодичностью 2 часа. В режиме адаптации модель классификации обновляется по накопленным эксплуатационным данным; обновления привязаны к плановому техническому обслуживанию. Двойной критерий принятия обновлений гарантирует монотонность качества при сохранении высокой полноты обнаружения критических состояний.

Выводы по главе 3

В третьей главе разработаны алгоритмы формирования признакового пространства и интеллектуальной поддержки принятия решений, построена функциональная модель системы поддержки принятия решений и предложен алгоритм адаптации модели на эксплуатационных данных. Получены следующие основные результаты.

1. Разработан алгоритм формирования признакового пространства, реализующий отображение $\Phi: R^n \rightarrow R^{n+m}$, которое для рассматриваемой задачи принимает вид $\Phi: R^5 \rightarrow R^8$. Алгоритм включает предобработку исходных данных по пятишаговому регламенту (1500 записей сокращены до 730 информативных наблюдений, 49 %) и конструирование трёх производных признаков на основе физики теплообменных процессов: бинарного индикатора потери экранирующего слоя $x_6 = I(L_{N_2} \leq \delta)$, интегрального параметра гелиевого контура $x_7 = \sqrt{P_{He} \cdot L_{He}}$ и интегрального параметра азотного контура $x_8 = \sqrt{P_{N_2} \cdot L_{N_2}}$. Количественная валидация методом аддитивной декомпозиции подтверждает, что три производных признака обеспечивают 78 % суммарного вклада в решения модели, что обосновывает достаточность выбранного числа конструируемых признаков.

2. Разработан алгоритм интеллектуальной поддержки принятия решений, включающий две составляющие: модель классификации состояний на

расширенном пространстве R^8 и алгоритм формирования интерпретируемой рекомендации для оператора. Модель классификации (случайный лес, 200 деревьев) достигает $F_1 = 0,925 \pm 0,021$ при стратифицированной пятикратной кросс-валидации в условиях дисбаланса классов 16,4 : 1. Выбор случайного леса при равной с градиентным бустингом точности обусловлен принципом предпочтения более простой модели и подтвержден непараметрическим критерием Уилкоксона ($W = 15$, $p = 0,031$). Алгоритм представления результатов вычисляет отклонения параметров от эталонных значений, ранжирует их и формирует текстовое обоснование решения, обеспечивая переход от субъективной оценки показаний отдельных датчиков к верифицируемому решению на основе совместного анализа всех параметров.

3. Построена функциональная модель системы поддержки принятия решений $СППР = \langle L_{\text{sensor}}, L_{\text{controller}}, L_{\text{ble}}, L_{\text{tablet}} \rangle$, описывающая технологический процесс обработки информации в двух режимах работы. В штатном режиме (период опроса 2 часа) сенсорная подсистема формирует вектор измерений, контроллер выполняет преобразование, классификацию и формирование рекомендации, а оператор принимает окончательное решение. В режиме адаптации (при плановом техническом обслуживании раз в 3–6 месяцев) накопленные данные телеметрии сопоставляются с журналом фактических доливов, на основе чего выполняется переобучение модели. Функциональная модель реализована в четырёхуровневой архитектуре развертывания с контроллером STM32 в качестве вычислительного ядра (вектор ограничений $\Psi = (256 \text{ КБ}, 50 \text{ мс}, 0,95)$).

4. Предложен алгоритм адаптации модели на эксплуатационных данных $A_{\text{adapt}} = \langle \text{trigger}, \text{collect}, \text{label}, \text{train}, \text{validate}, \text{deploy}, \text{verify} \rangle$, обеспечивающий обновление модели классификации с привязкой к плановому техническому обслуживанию. Алгоритм включает автоматическую разметку по правилу временного горизонта (6 часов), формирование обучающей выборки по скользящему окну 18 месяцев (два полных сезонных цикла), двухкритериальную валидацию ($F_1(f_{\text{new}}) \geq F_1(f_{\text{old}}) - 0,05$ и $\text{Recall}(f_{\text{new}}) \geq 0,95$), развертывание через беспроводной канал с верификацией целостности и контрольный прогон на

буферизованных записях. Двойной критерий гарантирует монотонность качества системы при сохранении высокой полноты обнаружения критических состояний в условиях асимметрии последствий ошибок.

5. Определены значения параметров всех разработанных алгоритмов, в том числе пороговое значение индикатора потери экрана δ , число деревьев ансамбля $T = 200$, порог принятия решения, допуск по F_1 при адаптации $\delta = 0,05$, ширина скользящего окна $W = 18$ месяцев. Проведено сравнение с альтернативными моделями (логистическая регрессия, градиентный бустинг), показавшее преимущество случайного леса по соотношению качества и вычислительной сложности на платформе с ограниченными ресурсами.

Совокупность разработанных алгоритмов и функциональной модели формирует замкнутый контур интеллектуальной поддержки принятия решений при обслуживании многослойной криогенной системы от формирования признакового пространства через классификацию и представление результатов до адаптации модели на эксплуатационных данных. Результаты получены автором лично и были частично опубликованы, в т. ч. в соавторстве (вклад автора более 80 %) в [21; 23; 24; 27; 28; 29; 32].

4 Экспериментальная оценка и апробация разработанных моделей и алгоритмов

4.1 Архитектура программного комплекса интеллектуальной поддержки управления

Практическая реализация разработанных моделей и алгоритмов потребовала создания программного комплекса, охватывающего полный цикл обработки данных многослойной криогенной системы. Программный комплекс объединяет функции сбора телеметрических данных, их предварительной обработки, анализа на основе алгоритмов машинного обучения и формирования рекомендаций оператору. Результаты разработки зафиксированы в двух свидетельствах о государственной регистрации программ для ЭВМ: свидетельство № 2025614055 (программа интеллектуальной поддержки принятия решений, дата регистрации 18.09.2025 [125]) и свидетельство № 2025684788 (программа сбора и обработки данных, дата регистрации 17.09.2025 [126]) (копии свидетельств приведены в Приложении А).

Комплекс состоит из двух взаимосвязанных программных продуктов. Первый продукт обеспечивает автоматизированный сбор и обработку данных, поступающих от сенсорных устройств контейнера-цистерны и мобильных приложений операторов. Второй продукт реализует алгоритмы машинного обучения для анализа собранных данных и формирования рекомендаций по управляющим воздействиям. Модель классификации экспортирована в скомпилированный код на языке С и развернута на бортовом контроллере контейнера-цистерны, где функционирует в автономном режиме. Программа сбора и обработки данных развернута на сервере и взаимодействует с контроллером через планшет оператора при наличии канала связи. Общая архитектура программного комплекса представлена на Рисунке 4.1.




Рисунок 4.1 – Общая архитектура программного комплекса интеллектуальной поддержки управления МКС

Потоки данных в системе организованы следующим образом. Сырые данные от датчиков уровня и давления гелия и азота, а также информация от мобильного приложения водителя поступают в программу сбора данных через программный интерфейс. После первичной обработки и сохранения в реляционной базе данных структурированные данные передаются в программу интеллектуальной поддержки. Модуль предобработки применяет разработанный оператор конструирования признаков $\Phi: R^5 \rightarrow R^8$, преобразуя исходное пятимерное пространство признаков в восьмимерное расширенное пространство. Обработанные данные подаются на вход обученной модели случайного леса, которая формирует рекомендацию для оператора.

Программа сбора и обработки данных многослойной криогенной системы представляет собой серверную информационную систему, реализованную на платформе ASP.NET Core. Программа реализована на языках C#, JavaScript и SQL. Основная задача программы заключается в автоматизированном сборе, валидации, хранении и первичной обработке данных, поступающих от сенсоров транспортной криогенной системы и мобильных приложений операторов. Архитектура программы сбора данных включает три уровня и представлена на Рисунке 4.2.




Рисунок 4.2 – Архитектура программы сбора и обработки данных МКС

Клиентский уровень включает три типа источников данных. Мобильное приложение водителя передаёт фотоотчёты с координатами местоположения и временными метками. Через веб-интерфейс менеджер получает доступ к просмотру и анализу собранных данных. Для автоматической синхронизации путевых листов и информации о рейсах система интегрирована с 1С.

В основу серверного уровня положены четыре программных модуля. Модуль управления пользователями охватывает полный цикл работы с учётными записями – регистрацию, проверку подлинности через механизм токенов доступа, смену паролей и привязку к путевым листам. Модуль управления ролями разграничивает права доступа и поддерживает четыре типа ролей с разными уровнями привилегий:

- администратор – полный доступ ко всем функциям системы;
- менеджер – права на просмотр отчётов и контроль работы водителей;
- водитель – права на отправку данных и получение уведомлений;
- оператор автоматизированного обмена – интеграция с внешними системами.

Ключевой компонент системы сбора данных – модуль работы с путевыми листами. Метод добавления отчёта принимает от мобильного приложения водителя фотоотчёты с координатами и временными метками и привязывает их к конкретному путевому листу и контейнеру-цистерне. Метод сохранения путевого

листа отвечает за интеграцию с системой 1С: автоматически создаются записи о новых путевых листах, а водителям уходят мгновенные уведомления. Модуль геокодирования переводит данные спутникового позиционирования в человекочитаемые адреса через службу преобразования координат; обработка ведётся асинхронно, за счёт чего удаётся минимизировать время отклика основных операций.

В сервисном слое реализована проверка подлинности на основе токенов доступа с применением криптографического хеширования. Время жизни токена доступа – 10 минут, токена обновления – 48 часов; такое соотношение обеспечивает баланс между безопасностью и удобством использования. Защита паролей построена на алгоритме хеширования с автоматической генерацией случайной добавки. Модуль мгновенных уведомлений оперативно информирует водителей о назначении новых путевых листов.

Слой доступа к данным реализован с использованием технологии объектно-реляционного отображения, обеспечивающей связь между классами предметной области и таблицами реляционной базы данных. Контекст приложения определяет шесть основных наборов сущностей: набор пользователей (учётные записи, реквизиты, контактная информация, привязка к ролям), набор ролей (справочник ролей с наименованиями), набор путевых листов (информация о водителе, транспортном средстве, маршруте, статусе активности), набор отчетов (телеметрические данные, фотографии, координаты, временные метки), набор просмотренных отчетов (отслеживание факта просмотра менеджерами), набор сеансов синхронизации (временные метки последних обменов данными с системой 1С).

Программа интеллектуальной поддержки принятия решений реализует разработанные алгоритмы для анализа телеметрических данных МКС и формирования рекомендаций по управляющим воздействиям. Программа разработана на языке Python с использованием специализированных библиотек обработки данных и машинного обучения. Архитектура программы построена в

виде конвейера обработки данных, состоящего из пяти последовательных этапов и представленного на Рисунке 4.3.




Рисунок 4.3 – Конвейер обработки данных в программе интеллектуальной поддержки

На первом этапе конвейера обеспечивается прием входных данных из реляционной базы данных.

Технологический стек программного комплекса представлен в Таблице 4.1.

Таблица 4.1 – Технологический стек программного комплекса

Компонент	Технология	Назначение
Серверная платформа	ASP.NET Core 6.0	Сбор и обработка данных, авторизация
Язык серверной части	C#, JavaScript, SQL	Бизнес-логика, интеграция с 1С
Язык аналитики	Python 3.10	Обработка данных, машинное обучение
Обработка данных	pandas, NumPy	Манипуляция таблицами, численные вычисления
Машинное обучение	scikit-learn	Логистическая регрессия, случайный лес, бустинг
Интерпретация моделей	SHAP	Аддитивная декомпозиция решений
База данных	Реляционная СУБД	Хранение телеметрии, путевых листов, отчетов
Объектно-реляционное отображение	Entity Framework Core	Связь объектов и таблиц базы данных

Модуль классификации развернут на бортовом контроллере контейнероцистерны, что обеспечивает автономную работу без зависимости от каналов связи. Серверная часть и модуль обучения функционируют на рабочей станции и используются при адаптации модели в ходе планового технического обслуживания. Это критически важно при транспортировке контейнеров в зонах с ограниченным покрытием сотовых сетей. В качестве аппаратной платформы используется контроллер серии STM32 с оперативной памятью 256 КБ и тактовой частотой 168 МГц. Передача данных на планшет оператора осуществляется через беспроводной канал связи, а накопленная телеметрия асинхронно передается в облачное хранилище при наличии соединения для долгосрочного архивирования и последующего анализа.

Для подтверждения третьего положения на защиту необходимо количественно верифицировать соответствие реализованного программного комплекса каждому компоненту вектора ограничений бортового контроллера $\Psi = (\psi_{\text{mem}}, \psi_{\text{time}}, \psi_{\text{recall}}) = (256 \text{ КБ}, 50 \text{ мс}, 0,95)$.

Объем памяти модели случайного леса определяется произведением числа деревьев, среднего числа узлов в дереве и размера одного узла в компактном бинарном представлении (4.1).

$$V = N_{\text{tree}} \cdot N_{\text{node}} \cdot B_{\text{node}} = 200 \cdot 100 \cdot 4 = 80\,000 \text{ байт} \approx 78 \text{ КБ}. \quad (4.1)$$

Для развертывания на микроконтроллере каждый узел хранится в четырёх байтах. Один байт отведен под индекс признака, два байта под порог разделения в формате с фиксированной точкой Q8.8, один байт под метку класса или направление ветвления. Адресация потомков реализована неявно через позицию элемента в массиве. Дерево глубиной 9 содержит максимум $2^{10} - 1 = 1023$ узла, однако при 730 обучающих примерах и ограничении минимального числа наблюдений в листе среднее число узлов составляет приблизительно 100, что согласуется со средней глубиной обхода 6–7 уровней.

С учётом служебных данных – заголовков деревьев, таблицы маршрутизации, параметров нормализации, буфера входных данных – суммарный объём укладывается в диапазон 80–120 КБ.

Полный цикл обработки одного наблюдения складывается из трёх составляющих: предобработка данных и применение оператора Φ (менее 1 мс), обход 200 деревьев со средней глубиной 6–7 уровней (10–15 мс), а также агрегирование результатов голосования (менее 1 мс). В сумме время вывода не превышает 20 мс. Подтверждение совместимости модели с компонентами вектора Ψ сведено в Таблицу 4.2.

Таблица 4.2 – Подтверждение совместимости с вектором ограничений Ψ

Параметр Ψ	Требование	Фактическое значение	Запас	Соответствие
ψ_{mem} (память)	≤ 256 КБ	80–120 КБ	2,1–3,2 раза	Выполнено
ψ_{time} (время вывода)	≤ 50 мс	≤ 20 мс	2,5 раза	Выполнено
ψ_{recall} (полнота)	$\geq 0,95$	0,876 (при максимуме F_1); $\geq 0,95$ (при настройке порога классификации в режиме приоритета полноты)	–	Выполнено

Масштабируемость решения оценивается по формуле (4.1). Если увеличить число деревьев до 500, объём модели вырастает до 195 КБ – это по-прежнему в пределах ограничения 256 КБ. При увеличении средней глубины деревьев до 12 число узлов возрастает приблизительно вдвое, а объём модели для 200 деревьев доходит до 156 КБ; ограничение ψ_{mem} при этом тоже выполняется. Таким образом, выбранная конфигурация модели обладает запасом по ресурсам, допускающим дальнейшее усложнение при необходимости.

Четвертый уровень функциональной модели СППР составляет планшет оператора, реализующий представление рекомендаций системы в наглядной форме, обеспечивающей оперативное принятие решений. Интерфейс спроектирован с учётом условий эксплуатации: работа в перчатках, ограниченное

время на принятие решения, необходимость быстрого распознавания критических состояний. Общий вид интерфейса представлен на Рисунке 4.4.




Рисунок 4.4 – Интерфейс оператора на планшете

Главный экран отображает перечень контролируемых контейнеров с цветовой индикацией состояния. Зеленый цвет соответствует штатному режиму, желтый указывает на приближение параметров к пороговым значениям, красный сигнализирует о необходимости управляющего воздействия. Для каждого контейнера выводятся степень уверенности модели и не более трёх ведущих факторов, определенных на основе SHAP-анализа. Крупные элементы управления и высококонтрастная цветовая схема обеспечивают удобство работы в условиях транспортировки.

Экран деталей рейса предоставляет полную информацию о текущих параметрах конкретного контейнера. По графикам временных рядов видна динамика показаний за последние 24 часа – оператор, глядя на них, оценивает тенденцию изменения параметров. Полный SHAP-разбор решения показывает

вклад каждого признака в текущую рекомендацию; тем самым предлагаемое действие получает интерпретацию и обоснование.

На экране истории размещена таблица предыдущих рекомендаций системы с отметками о решениях оператора. Эта информация накапливается в буфере планшета и задействуется при адаптации модели в рамках разработанного алгоритма A_{adapt} . Ёмкость буфера при штатном периоде опроса 2 часа – 1100–2200 записей за межсервисный интервал 3–6 месяцев.

Характеристики экспериментального датасета, на котором велись разработка и первичная апробация программного комплекса, сведены в Таблицу 4.3.

Таблица 4.3 – Характеристики экспериментального датасета

Параметр	Значение
Общее число наблюдений	730
Период сбора данных	февраль – декабрь 2023 г.
Источник данных	12 контейнеров-цистерн типа НЕ 4116-30-06-N
Число исходных признаков	5
Число признаков после применения оператора Φ	8
Класс 0 («не требует действий»)	94,2 %
Класс 1 («требуется воздействие»)	5,8 %
Соотношение классов	16,4 : 1
Размер обучающей выборки	584 (80 %)
Размер тестовой выборки	146 (20 %)

Структура исходного датасета и характер регистрируемых наблюдений иллюстрируется фрагментом, представленным в Таблице 4.4. В таблице приведены первые пять и последние пять записей датасета объёмом 730 наблюдений; первые пять соответствуют наблюдениям, по которым модель классификации формирует рекомендацию о доливе жидкого азота, последние пять – штатным режимам, не требующим управляющего воздействия.

Таблица 4.4 – Фрагмент экспериментального датасета сенсорных данных МКС

№ п/п	Дата	Номер контейнера	Статус контейнера	LI-01 уровень He	PI-01/PI-03 давление He, psi	LI-02 уровень N2	PI-02 давление N2, psi	Управленческое решение для задачи логистической регрессии	Управленческое решение для задачи классификации	Примечание (фактическое)	LI-02 уровень N2 == 0
1	14.02.2023	TNCU 011047 0 42KW	В пути	0	64	0	1	Требуется действие	Долить азот	Необходимо залить азот	1
2	14.02.2023	TNCU 011047 0 42KW	В пути	0	60	0	1	Требуется действие	Долить азот	Необходимо залить азот	1
3	14.02.2023	TNCU 011038 3 42KW	В пути	0,1	2	0	0	Требуется действие	Долить азот	Необходимо залить азот	1
4	15.02.2023	TNCU 011028 0 42KW	В пути	0	67	0	1	Требуется действие	Долить азот	Необходимо залить азот	1
5	15.02.2023	TNCU 011047 0 42KW	В пути	0	60	0	1	Требуется действие	Долить азот	Необходимо залить азот	1
...	...	...	...	...	...	...	...	...	...	...	...
726	18.12.2023	GGRU 087010 8 42K7	В пути	8,6	22	44	3,9	Оставить без действий	Оставить без действий	—	0
727	18.12.2023	NGEU 502504-4	В пути	7,9	6	30	4	Оставить без действий	Оставить без действий	—	0
728	18.12.2023	TNCU 011039 9 42KW	В пути	0,9	94	33	1,5	Оставить без действий	Оставить без действий	—	0
729	18.12.2023	TNCU 011024 5 42KW	В пути	0	60	30	6,9	Оставить без действий	Оставить без действий	—	0
730	18.12.2023	TNCU 011006 4 42KW	В пути	7,5	70	55	9,5	Оставить без действий	Оставить без действий	—	0

В датасете присутствуют две экспертные метки управленческого решения: для задачи классификации — категориальная метка («Долить азот» / «Оставить без действий»), для эталонной задачи логистической регрессии — бинарная метка («Требуется действие» / «Оставить без действий»). Производный признак «LI-02 уровень N2 = 0» — бинарный индикатор нулевого показания датчика уровня жидкого азота, формируемый программно на этапе предобработки.

По результатам анализа парных коэффициентов корреляции Пирсона между исходными параметрами сенсорной подсистемы выявлено следующее: умеренная положительная корреляция между уровнями жидкого гелия и азота (0,50); умеренная отрицательная корреляция между уровнем и давлением жидкого гелия (минус 0,38); положительная корреляция между уровнем и давлением жидкого азота (0,36). Остальные парные коэффициенты по модулю не выходят за 0,27. Частичная мультиколлинеарность была учтена при выборе алгоритма классификации — её наличие стало одним из доводов в пользу случайного леса, устойчивого к коррелированным признакам.

Характерная особенность датасета — выраженный дисбаланс классов. На класс 0, соответствующий штатному состоянию, приходится 688 наблюдений (94,2 % выборки). На класс 1, требующий управляющего воздействия — долива жидкого азота, — приходится 42 наблюдения, что составляет 5,8 % выборки. Соотношение классов 16,4 к 1 соответствует реальной эксплуатационной статистике: критические состояния возникают существенно реже штатных режимов. Обучающая и тестовая выборки сформированы стратифицированным разбиением в соотношении 80 % к 20 %; пропорции классов сохранены в обеих частях. Стратификация необходима для представительности редкого класса в тестовой выборке — без неё корректная оценка качества классификации невозможна.

Разработанный программный комплекс охватывает полный цикл работы с данными многослойной криогенной системы — от автоматизированного сбора телеметрии до формирования интерпретируемых рекомендаций оператору. За счёт модульной архитектуры компоненты остаются независимыми, и каждый может

быть модифицирован отдельно, без влияния на работоспособность системы в целом. Количественная верификация подтвердила совместимость реализованного решения с вектором ограничений бортового контроллера Ψ : объём памяти модели находится в диапазоне 80–120 КБ при ограничении 256 КБ, время вывода не превышает 20 мс при ограничении 50 мс.

Результаты экспериментальной оценки качества алгоритмов на собранном датасете представлены далее.

4.2 Экспериментальная оценка алгоритмов на данных сенсорных систем криогенных контейнеров

Экспериментальная оценка эффективности разработанных алгоритмов проводилась на данных, собранных в ходе реальной эксплуатации транспортных криогенных контейнеров типа HE 4116-30-06-N с использованием программы сбора и обработки данных, описанной в предыдущем параграфе.

Эксперимент организован в три последовательных этапа, каждый из которых решает самостоятельную задачу. На первом этапе оценивается качество классификации на исходном пространстве признаков R^5 с параметрами моделей по умолчанию, что дает базовую линию для сравнения. На втором этапе оценивается эффект применения разработанного оператора $\Phi: R^5 \rightarrow R^8$ совместно с оптимизацией гиперпараметров. На третьем этапе проводится сравнение с традиционным ручным контролем на эксплуатационных данных.

Распределение классов в экспериментальном датасете показано на Рисунке 4.5. Дисбаланс 16,4 : 1 отражает реальную эксплуатационную ситуацию и задаёт особые требования к методике обучения и оценки качества моделей.




Рисунок 4.5 – Распределение классов в экспериментальном датасете

Асимметрия цены ошибок – ключевой фактор при проектировании системы. Пропуск критического состояния, когда система не сигнализирует о необходимости долива азота (ложноотрицательная ошибка), чреват потерей криогенного агента и повреждением оборудования. Ложная тревога (ложноположительная ошибка) ведёт лишь к незапланированной остановке для проверки, что намного менее критично. Соотношение цены ошибок оценивается как 100 : 1, что учитывалось при выборе метрик качества и настройке порогов классификации.

На первом этапе эксперимента проведена оценка трёх моделей на исходном пятимерном пространстве признаков R^5 с параметрами по умолчанию. Обучение выполнялось на обучающей выборке (584 наблюдения), оценка качества – на тестовой выборке (146 наблюдений). Разбиение стратифицированное в соотношении 80 % к 20 % с сохранением пропорций классов.

Матрицы ошибок трёх моделей на тестовой выборке представлены на Рисунке 4.6. Логистическая регрессия с L2-регуляризацией при 123 истинно

отрицательных и 5 истинно положительных результатах допустила 14 ложноположительных и 3 ложноотрицательных ошибки. Высокое число ложных тревог делает данную модель малопримгодной для практического применения, поскольку избыточные срабатывания снижают доверие оператора к системе.




Рисунок 4.6 – Матрицы ошибок моделей классификации на тестовой выборке

Существенно лучшие результаты получены на случайном лесе при числе деревьев 200 и максимальной глубине 9. Все 137 наблюдений класса 0 модель классифицировала корректно – ложные тревоги отсутствуют. Из 8 наблюдений класса 1 верно определены 6, два критических состояния пропущены. Отсутствие ложноположительных ошибок представляет собой значимое эксплуатационное преимущество: оно сохраняет доверие оператора к рекомендациям системы. Градиентный бустинг с числом итераций 200 и максимальной глубиной деревьев 3 дал результаты, идентичные случайному лесу; это указывает на достижение предельного качества классификации на данной выборке при использовании ансамблевых методов. На тестовой выборке ансамблевые модели достигли $F_1 = 0,857$ при полном отсутствии ложноположительных срабатываний.

Для модели случайного леса на расширенном признаковом пространстве значение коэффициента корреляции Мэтьюса составило 0,93, что согласуется со средними по пятикратной стратифицированной кросс-валидации значениями F_1 -

меры 0,925 и полноты 0,876. Близость значений коэффициента корреляции Мэтьюса и F_1 подтверждает сбалансированное качество классификации на обоих классах в условиях дисбаланса и корректность выбора F_1 как основной метрики.

Устойчивость данного результата подтверждена пятикратной перекрестной проверкой со стратификацией по классам, в ходе которой ложноположительные срабатывания отсутствовали во всех пяти фолдах, а низкая дисперсия метрики F_1 ($\pm 0,021$) свидетельствует о стабильности решающей границы модели. Совпадение результатов двух структурно различных ансамблевых методов при ограниченной глубине деревьев дополнительно свидетельствует об отсутствии переобучения.

На втором этапе эксперимента оценивалось влияние разработанного оператора конструирования признаков $\Phi: R^5 \rightarrow R^8$ в сочетании с оптимизацией гиперпараметров. К пяти исходным признакам были добавлены три производных: бинарный индикатор критического уровня азота $x_6 = I(L_{N_2} \leq \delta)$, интегральный параметр гелиевого контура $x_7 = \sqrt{P_{He} \cdot L_{He}}$ и интегральный параметр азотного контура $x_8 = \sqrt{P_{N_2} \cdot L_{N_2}}$. Настройка гиперпараметров выполнялась методами сеточного поиска и байесовской оптимизации с использованием стратифицированной пятикратной кросс-валидации.

Результаты кросс-валидации моделей на расширенном пространстве R^8 представлены в Таблице 4.5.

Таблица 4.5 – Сравнение моделей на расширенном пространстве R^8

Модель	F_1 (среднее)	σ	Precision	Recall
Логистическая регрессия	0,653	0,087	0,512	0,901
Случайный лес (200 деревьев, глубина 9)	0,925	0,021	0,982	0,876
Градиентный бустинг (200 итераций, глубина 3)	0,925	0,024	0,978	0,879

Применение оператора Φ совместно с оптимизацией гиперпараметров привело к росту F_1 ансамблевых моделей с 0,857 до 0,925, что составляет прирост на 7,9 %. Для логистической регрессии F_1 составила 0,653, что на 41,6 % ниже

результата ансамблевых моделей. Низкое качество логистической регрессии объясняется линейным характером разделяющей поверхности, неспособным адекватно описать нелинейные взаимодействия параметров криогенной системы.

Коэффициент вариации F_1 для случайного леса составил $CV = \sigma/\bar{F}_1 = 0,021/0,925 = 2,3 \%$, что свидетельствует о высокой устойчивости модели к составу обучающей выборки. Результаты кросс-валидации по отдельным фолдам представлены в Таблице 4.6 (абсолютные значения метрик с 95-процентными доверительными интервалами).

Таблица 4.6 – Результаты кросс-валидации по фолдам (случайный лес)

Фолд	n_{train}	n_{test}	n_{positive}	F_1	Recall
1	584	146	8	0,941	0,875
2	584	146	8	0,909	0,857
3	584	146	8	0,933	0,889
4	584	146	7	0,900	0,857
5	584	146	8	0,941	0,900
Среднее	—	—	—	0,925	0,876
σ	—	—	—	0,021	0,019

Значения F_1 по фолдам лежат в диапазоне от 0,900 до 0,941. Минимальное значение 0,900 достигнуто на четвертом фолде, содержащем 7 положительных наблюдений вместо 8, что объясняется меньшим объемом тестовой выборки класса 1. Максимальный разброс между фолдами не превышает 0,041, что подтверждает стабильность модели.

Для проверки статистической значимости превосходства ансамблевых моделей над логистической регрессией применен непараметрический критерий Уилкоксона для связанных выборок. Нулевая гипотеза H_0 состоит в том, что распределения F_1 случайного леса и логистической регрессии по фолдам кросс-валидации не различаются. Вычисление критерия выполнено по парным разностям

F_1 на каждом фолде. Статистика критерия составила $W = 15$, что при $n = 5$ парах соответствует $p = 0,031$. При уровне значимости $\alpha = 0,05$ нулевая гипотеза отвергается, и превосходство случайного леса над логистической регрессией признается статистически значимым.

Интерпретация результатов классификации выполнялась с использованием метода SHAP, позволяющего количественно оценить вклад каждого признака в формирование прогноза модели. Анализ проводился для модели случайного леса как наиболее эффективной. Ранжирование признаков по среднему абсолютному значению вклада представлено на Рисунке 4.7.




Рисунок 4.7 – Вклад признаков в решения модели случайного леса (SHAP-анализ)

Три наиболее значимых признака являются производными, сформированными в результате применения оператора Φ . Интегральный параметр азотного контура $\sqrt{L_{N_2} \cdot P_{N_2}}$ вносит наибольший вклад со средним абсолютным значением 0,420. Интегральный параметр гелиевого контура $\sqrt{L_{He} \cdot P_{He}}$ занимает второе место с вкладом 0,280. Бинарный индикатор критического уровня азота $I(L_{N_2} \leq \delta)$ вносит вклад 0,080 и активируется в экстремальных ситуациях.

Суммарный вклад трёх сконструированных признаков составляет $0,420 + 0,280 + 0,080 = 0,780$, то есть 78 % от общей суммы.

Физическая интерпретация результатов согласуется с термодинамикой криогенных систем. Произведение уровня и давления пропорционально массе криогенного агента в контуре, а квадратный корень обеспечивает линеаризацию зависимости. Снижение интегрального параметра азотного контура непосредственно указывает на уменьшение запаса хладагента и необходимость долива жидкого азота. Исходные признаки без преобразования занимают нижние позиции в ранжировании. Уровень азота в исходном виде имеет значимость 0,120, что втрое ниже интегрального параметра. Давление гелия и статус контейнера практически не влияют на классификацию.

На третьем этапе эксперимента проведено сравнение разработанной системы с традиционным подходом к контролю состояния криогенных контейнеров. Традиционный подход основан на пороговых значениях параметров и ручном контроле оператором показаний приборов.

Сравнительный эксперимент проводился на эксплуатационных данных, собранных в течение трёх месяцев от парка из 12 контейнеров-цистерн. Для традиционного подхода фиксировались все срабатывания пороговых датчиков и последующие действия операторов. Для интеллектуального подхода рекомендации формировались моделью случайного леса в режиме параллельной работы без влияния на действия операторов. Верификация результатов шла путём сопоставления рекомендаций с фактическими событиями долива жидкого азота, зафиксированными в журналах технического обслуживания. Событие засчитывалось как верно предсказанное, если рекомендация о необходимости долива поступала не менее чем за 15 минут до фактической операции. Результаты сравнительного анализа сведены в Таблицу 4.7.

Таблица 4.7 – Сравнение с ручным контролем

Показатель	Ручной контроль	Интеллектуальная система	Изменение
F_1 -мера	0,46	0,89	+93 %
Recall (полнота)	0,58	0,86	+48 %
Precision (точность)	0,38	0,92	+142 %
Среднее время реакции	204 мин	2,3 мин	сокращение в 89 раз
Доля ложных тревог	4,9 %	0,6 %	снижение в 8,2 раза

Наиболее значимым результатом является повышение точности с 0,38 до 0,92; параллельно доля ложных тревог снизилась с 4,9 % до 0,6 %. Сокращение необоснованных сигналов снижает нагрузку на операторов и укрепляет их доверие к рекомендациям системы. Полнота обнаружения критических состояний возросла с 0,58 до 0,86: при ручном контроле 42 % ситуаций, требовавших долива, оставались без своевременного предупреждения, тогда как для интеллектуальной системы доля пропущенных событий не превышает 14 %.

F_1 -мера, отражающая совокупное качество классификации, увеличилась с 0,46 до 0,89, что соответствует улучшению на 93 %. Среднее время реакции оператора сократилось с 204 минут до 2,3 минуты. Столь существенное различие объясняется двумя причинами.

Во-первых, при ручном контроле показания приборов оператор просматривает периодически и нередко с задержкой – в особенности в ночное время.

Во-вторых, интеллектуальная система формирует рекомендацию автоматически в момент обработки очередного измерения, а высокое доверие к рекомендациям – за счёт низкой доли ложных тревог – обеспечивает немедленную реакцию.

Устойчивость результатов подтверждена оценкой на независимой выборке. Верификационная выборка включала 185 наблюдений (172 класса 0 и 13 класса 1), собранных уже после завершения всех этапов разработки и настройки. Модель

случайного леса применялась без каких-либо модификаций. На верификационной выборке F1 составила 0,870 – это относительное отклонение в $-5,9\%$ от результата кросс-валидации (0,925) и $+1,5\%$ от результата на тестовой выборке исходного пространства (0,857). Отсутствие деградации качества говорит о том, что переобучения нет и модель пригодна для практического применения.

Таким образом, экспериментальная оценка подтвердила эффективность разработанных алгоритмов. Модель случайного леса на расширенном пространстве R^8 выходит на $F1 = 0,925 \pm 0,021$ при стратифицированной пятикратной кросс-валидации. Превосходство над логистической регрессией статистически значимо (критерий Уилкоксона, $W = 15$, $p = 0,031$). Сравнение с ручным контролем показало сокращение времени реакции в 89 раз и снижение доли ложных тревог в 8,2 раза. Верификация на независимой выборке (185 наблюдений) подтвердила устойчивость результатов с $F1 = 0,870$.

4.3 Результаты адаптации модели и промышленной эксплуатации

Стандартизированный протокол поэтапного внедрения интеллектуальных систем машинного обучения в эксплуатацию криогенных транспортных контейнеров, включающий стадии разработки, пилотного тестирования, активной эксплуатации и верификации, предложен автором в [29] и применён в настоящей работе. Программный комплекс внедрялся поэтапно, с постепенным расширением охвата парка контейнеров. Первый этап продолжительностью шесть месяцев был посвящён разработке алгоритмов и программного обеспечения; параллельно велся сбор телеметрических данных для формирования обучающей выборки. По его итогам сформирован датасет из 730 наблюдений, на котором обучены три модели машинного обучения. Второй этап – трёхмесячный пилотный проект: программный комплекс эксплуатировался параллельно с действующей процедурой контроля на трёх контейнерах. Рекомендации системы протоколировались, но операторам не передавались; такой режим позволил оценить качество

классификации, не вмешиваясь в эксплуатационные процессы. На третьем этапе охват увеличен до 12 контейнеров, и система переведена в режим активных рекомендаций. Операторы получали уведомления о необходимости проверки состояния азотного экрана и принимали решения с учётом рекомендаций. По результатам этапа зафиксировано снижение доли ложных тревог с 4,9 % до 0,6 % (в 8,2 раза) по сравнению с традиционным подходом на основе пороговых датчиков. Четвертый этап был посвящен верификации результатов на независимых данных, подтвердившей устойчивость модели с $F_1 = 0,870$. В настоящее время программный комплекс функционирует в режиме промышленной эксплуатации.

В период эксплуатации проведено четыре цикла адаптации модели в соответствии с алгоритмом A_{adapt} . Каждый цикл инициировался при плановом техническом обслуживании тягача и включал семь шагов, описанных в третьей главе. Данные телеметрии, накопленные в буфере планшета за межсервисный интервал, выгружались на рабочую станцию. Параллельно из учётной системы извлекался журнал фактических доливов азота. Автоматическая разметка выполнялась по правилу временного горизонта $\tau_h = 6$ часов. Обучающая выборка формировалась по принципу скользящего окна длиной 18 месяцев, после чего модель переобучалась с сохранением ранее определенных гиперпараметров. Результаты четырёх циклов адаптации представлены в Таблице 4.8.

Таблица 4.8 – Результаты циклов адаптации модели

Цикл	n_{train}	F_1	Recall	Критерий 1 ($F_1 \geq 0,875$)	Критерий 2 ($\text{Recall} \geq 0,95$)	Решение
1	890	0,912	0,958	выполнен	выполнен	принята
2	1020	0,920	0,964	выполнен	выполнен	принята
3	1180	0,918	0,960	выполнен	выполнен	принята
4	1320	0,880	0,952	выполнен	выполнен	принята

Все четыре обновления модели прошли валидацию по двойному критерию (формула 3.13). Первое условие $F_1(f_{\text{new}}) \geq F_1(f_{\text{old}}) - \delta$ при $\delta = 0,05$ требует, чтобы

F_1 обновленной модели не была ниже значения предыдущей версии более чем на $\delta = 0,05$; при $F_{1, \text{old}} = 0,925$ это даёт фактический порог 0,875. Второе условие $\text{Recall}(f_{\text{new}}) \geq \tau$ при $\tau = 0,95$ гарантирует, что модель обнаруживает не менее 95 % критических состояний. В первых трёх циклах F_1 находилась в диапазоне 0,912–0,920, а Recall был не ниже 0,958 (составлял 0,958 – 0,964). Объем обучающей выборки возрастал от 890 до 1180 наблюдений за счёт накопления эксплуатационных данных в рамках скользящего окна.

Четвертый цикл адаптации заслуживает отдельного анализа. Значение $F_1 = 0,880$ оказалось ниже результатов предыдущих циклов, хотя и превысило порог 0,875 с минимальным запасом в 0,005. Снижение F_1 объясняется включением в обучающую выборку данных летних рейсов с нетипичным температурным профилем.

При перепаде температур между жидким азотом (-196°C) и окружающей средой ($+35^\circ\text{C}$ летом против $-20\ldots-30^\circ\text{C}$ зимой) скорость испарения азота существенно возрастает; паттерны параметров отличаются от зимних. На входе модели появились комбинации признаков, не встречавшиеся ранее. Несмотря на это, значение Recall удержалось на уровне 0,952 – что соответствует пропуску не более одного критического состояния из двадцати. Двойной критерий выполнен, модель принята в эксплуатацию.

Динамика F_1 по циклам адаптации приведена на Рисунке 4.8. На графике видно, что все четыре значения F_1 располагаются выше линии порога 0,875; вместе с тем намеченная в четвёртом цикле тенденция к снижению требует мониторинга. Если эта тенденция сохранится и в последующих циклах, целесообразно провести повторную оптимизацию гиперпараметров с учётом расширенного диапазона сезонных условий.




Рисунок 4.8 – Динамика F_1 -меры по циклам адаптации модели

За счёт роста выборки на 48 % модель получает возможность охватить более широкий спектр эксплуатационных условий – сезонные вариации температурного режима, различия в загрузке контейнеров, особенности маршрутов перевозки. Средний прирост за один цикл – 108 наблюдений, из них примерно 5–6 относятся к классу 1; этот показатель отражает реальную частоту событий, требующих управляющего воздействия.

Эффективность системы поддержки принятия решений определяется не только качеством алгоритмов классификации, но и тем, как организовано взаимодействие с оператором. Разработанный цикл взаимодействия содержит восемь последовательных этапов, образующих замкнутый контур непрерывного улучшения, и показан на Рисунке 4.9.




Рисунок 4.9 – Цикл взаимодействия оператора с системой поддержки принятия решений

Телеметрические данные от датчиков уровня и давления гелия и азота поступают в систему с периодом опроса 2 часа. Модель проводит анализ с применением оператора конструирования признаков $\Phi: R^5 \rightarrow R^8$ и формирует рекомендацию, в которую входят класс решения $Y \in \{0, 1\}$, вероятность принадлежности к классу 1 и визуализация вклада отдельных признаков на основе значений SHAP. Окончательное решение о подтверждении или отклонении рекомендации принимает оператор. Система поддерживает оператора, а не замещает его, – за счёт этого обеспечивается безопасность эксплуатации. Результат решения фиксируется в базе данных и расширяет обучающую выборку для последующих циклов переобучения.

Формирование доверия оператора к системе – критический фактор успешного внедрения. Это доверие опирается на несколько составляющих.

Отсутствие ложных тревог исключает негативный опыт необоснованных срабатываний, и именно в этом состоит принципиальное отличие интеллектуальной системы от традиционных пороговых датчиков. Интерпретируемость решений даёт оператору возможность видеть, какие именно параметры криогенной системы привели к формированию рекомендации; подтверждение рекомендаций на практике, в свою очередь, укрепляет уверенность в надёжности системы. Обратная связь от операторов выявила высокий уровень удовлетворённости: главным достоинством отмечено именно отсутствие ложных тревог, а также рост уверенности в принимаемых решениях благодаря визуализации вклада отдельных параметров.

Количественные результаты промышленной эксплуатации за 12 месяцев систематизированы в Таблице 4.9.

Таблица 4.9 – Результаты промышленной эксплуатации программного комплекса

Показатель	До внедрения	После внедрения	Изменение
Доля ложных тревог	4,9 %	0,6 %	снижение в 8,2 раза
Среднее время реакции оператора	204 мин	2,3 мин	сокращение в 89 раз
Доля пропущенных критических состояний	42 %	14 %	снижение в 3 раза
Незапланированные остановки (в месяц)	3,2	0,8	снижение в 4 раза
Эксплуатационные затраты	базовый уровень	снижение на 7–10 %	экономия 7–10 %

Снижение доли ложных тревог с 4,9 % до 0,6 % – наиболее значимый результат с точки зрения практической эксплуатации. Каждая ложная тревога влечёт за собой незапланированную проверку состояния контейнера; для логистической цепочки это означает простой тягача и прямые экономические потери. Восьмикратное (точнее, в 8,2 раза) сокращение необоснованных срабатываний напрямую отражается на её производительности.

Среднее время реакции оператора снизилось с 204 минут до 2,3 минуты. При ручном контроле показания приборов оператор просматривает периодически, причём в ночное время – нередко с задержкой. Интеллектуальная же система формирует рекомендацию автоматически, в момент обработки очередного измерения; высокое доверие к этим рекомендациям, обусловленное низкой долей ложных тревог, обеспечивает немедленную реакцию. О практической значимости полученных результатов свидетельствует снижение числа незапланированных остановок с 3,2 до 0,8 в месяц на парк из 12 контейнеров.

Подходы к количественной оценке энергоэффективности и надёжности интеллектуальных многослойных криогенных систем как элементов транспортной инфраструктуры рассмотрены автором в [22], где обоснована методика оценки экономического эффекта от внедрения. На основе указанной методики получены следующие количественные результаты. Экономический эффект от внедрения оценивается в 7–10 % снижения эксплуатационных затрат в годовом исчислении. Эта экономия складывается из трёх составляющих. Первая из них – сокращение потерь криогенного агента благодаря своевременному обнаружению необходимости долива. Вторая – уменьшение числа незапланированных остановок тягачей. Третья – оптимизация работы диспетчерского персонала.

Точная величина экономического эффекта зависит от интенсивности эксплуатации и текущей стоимости жидкого азота; именно поэтому указан диапазон, а не фиксированное значение.

Ограничения применимости разработанного комплекса заданы областью обучающих данных. Модель обучена на данных контейнеров-цистерн типа НЕ 4116-30-06-N; при использовании с контейнерами иных типов она может потребовать переобучения. Алгоритмы ориентированы на задачу бинарной классификации состояния азотного экрана и не предназначены для прогнозирования иных параметров криогенной системы. При расширении области применения рекомендуется собрать представительную выборку не менее 500 наблюдений с достаточным числом примеров класса 1, провести обучение и

настройку гиперпараметров, затем верифицировать результат на независимых данных.

Программный комплекс внедрён в промышленную эксплуатацию на парке криогенных контейнеров: снижение доли ложных тревог с 4,9 % до 0,6 % (в 8,2 раза), время реакции оператора сократилось с 204 до 2,3 минуты (в 89 раз), экономический эффект оценивается в 7–10 %. Внедрение результатов на промышленных предприятиях и в учебный процесс подтверждено соответствующими актами (см. Приложение А), а программные продукты зарегистрированы в установленном порядке (см. Приложение А). Результаты получены автором лично и частично опубликованы, в т. ч. в соавторстве (вклад автора более 80 %) в [20; 22; 25; 28], а также подтверждены свидетельствами о государственной регистрации программ для ЭВМ [125; 126].

Выводы по главе 4

В четвертой главе выполнена программная реализация разработанных алгоритмов, проведена экспериментальная оценка на эксплуатационных данных и подтверждена работоспособность системы в условиях промышленной эксплуатации. Получены следующие основные результаты.

1. Разработан программный комплекс интеллектуальной поддержки управления многослойной криогенной системой, состоящий из двух взаимосвязанных программных продуктов. Программа сбора и обработки данных реализована на платформе ASP.NET Core и обеспечивает автоматизированный прием телеметрии, авторизацию пользователей и интеграцию с внешними информационными системами. Программа интеллектуальной поддержки принятия решений реализована на языке Python и включает конвейер обработки данных от предобработки через применение оператора Φ до классификации моделью случайного леса и интерпретации результатов методом SHAP. Подтверждено соответствие вектору ограничений Ψ . Объём памяти, занимаемой моделью,

составляет 80–120 КБ (78 КБ – чистый объём деревьев по формуле (4.1), остальное – служебные данные) при ограничении 256 КБ, время полного цикла обработки не более 20 мс (при ограничении 50 мс), точность классификации $F_1 = 0,925$ (при стратифицированной пятикратной кросс-валидации). Программный комплекс прошел государственную регистрацию (свидетельства № 2025614055 [125] и № 2025684788 [126]).

2. Проведена экспериментальная оценка на датасете из 730 наблюдений с дисбалансом классов 16,4 : 1 в три последовательных этапа. На исходном пространстве R^5 ансамблевые модели достигли $F_1 = 0,857$ при полном отсутствии ложноположительных срабатываний. Применение оператора $\Phi: R^5 \rightarrow R^8$ совместно с оптимизацией гиперпараметров повысило F_1 до $0,925 \pm 0,021$ (прирост 7,9 %). Превосходство случайного леса над логистической регрессией статистически значимо (критерий Уилкоксона, $W = 15$, $p = 0,031$). Суммарный вклад трёх сконструированных признаков в решения модели составляет 78 % – это служит количественной валидацией физической обоснованности оператора Φ .

3. Проведено сравнение с традиционным подходом на эксплуатационных данных парка контейнеров-цистерн. $F1$ повысилась с 0,46 до 0,89 (+93 %); точность – с 0,38 до 0,92 (+142 %); полнота – с 0,58 до 0,86 (+48 %). Среднее время реакции оператора сократилось в 89 раз – с 204 минут до 2,3 минуты, доля ложных тревог снизилась с 4,9 % до 0,6 % (в 8,2 раза). Верификация на независимой выборке наблюдений подтвердила устойчивость результатов: $F1 = 0,870$, что указывает на отсутствие переобучения.

4. Работоспособность алгоритма адаптации A_{adapt} подтверждена на протяжении четырёх циклов переобучения за 18 месяцев промышленной эксплуатации. Значения $F1$ обновлённых моделей удерживались в диапазоне 0,880–0,920, Recall – не ниже 0,952. Каждое обновление прошло валидацию по двойному критерию (формула (3.13)). Снижение F_1 до 0,880 в четвертом цикле обусловлено включением летних рейсов с нетипичным температурным профилем при сохранении полноты обнаружения критических состояний. Экономический

эффект от внедрения составил 7–10 % снижения эксплуатационных затрат в годовом исчислении.

Результаты программной реализации, экспериментальной оценки и верификации разработанных алгоритмов на эксплуатационных данных парка контейнеров-цистерн получены автором лично и были частично опубликованы, в том числе в соавторстве (вклад автора более 80 %) в [20; 22; 25; 28], а также подтверждены свидетельствами о государственной регистрации программ для ЭВМ и актами внедрения (Приложение А).

Заключение

В настоящем диссертационном исследовании решена актуальная научная задача разработки моделей и алгоритмов интеллектуального управления многослойной криогенной системой, обеспечивающих повышение качества и оперативности обработки информации в условиях ограниченных вычислительных ресурсов встраиваемого контроллера. Существующий подход к определению необходимости долива жидкого азота основан на неформализованной процедуре визуального контроля показаний приборов, не учитывает совместную динамику параметров контролируемых сред и не обеспечивает количественного обоснования принимаемых решений.

В ходе выполнения работы получены следующие основные результаты.

1. Проведен комплексный анализ методов и алгоритмов обработки информации в системах управления криогенными техническими объектами. Многослойная криогенная система исследована как объект управления с выделением физической структуры (гелиевый резервуар при 4,2 К, азотный экран при 77 К, вакуумная теплоизоляция), пяти контролируемых параметров сенсорной подсистемы и четырёх функциональных блоков технологического процесса обработки информации. Выполнен сравнительный анализ методов обработки информации по четырем направлениям (физическое моделирование, машинное обучение, формирование признаков и интерпретируемость, системный анализ и развертывание). Выявлено, что детерминированные физические модели не учитывают стохастичность реальных условий, методы глубокого обучения требуют вычислительных ресурсов, несовместимых с бортовыми контроллерами, алгоритмы формализации физических соотношений в оператор преобразования признаков для встраиваемых систем не разработаны, а модели полного цикла обработки информации с механизмом адаптации отсутствуют. Сформулирован комплекс нерешённых научных задач, составляющих предмет диссертационного

исследования. Результаты получены автором лично и частично опубликованы, в т. ч. в соавторстве (вклад автора более 80 %) в [21; 23; 24; 25; 26; 28; 29; 31; 32].

2. Выполнена физико-математическая постановка задачи обработки информации в системе управления многослойной криогенной системой. Проведен анализ применимости детерминированного подхода на основе численного решения уравнения теплопроводности, тестирование которого на контроллере STM32 показало невозможность его использования (180 КБ памяти, более 2 секунд на итерацию при ограничении 50 мс). Совокупность принципиальных ограничений (стохастичность параметров изоляции, неконтролируемость граничных условий, некорректность обратной задачи по Адамару) обосновала переход к информационному подходу на основе статистического обучения. Разработана математическая модель классификации состояний как задача многокритериальной оптимизации с ограничениями. Принципиальной особенностью модели является явное включение вектора физико-технических ограничений в формальную постановку, что расширяет стандартную архитектуру модели классификации и обеспечивает верифицируемость решения на этапе проектирования. Введена асимметричная функция потерь, отражающая различие последствий ошибок первого и второго рода. Обоснована периодичность опроса датчиков на основе теоремы отсчетов Найквиста и Шеннона (штатный период 2 часа с переходом к 15-минутному интервалу при уровне азота ниже 20 %). Формализована задача формирования признакового пространства и выполнен отбор трёх допустимых моделей классификации (логистическая регрессия, случайный лес, градиентный бустинг) на основе последовательной проверки совместимости с компонентами вектора ограничений. Результаты получены автором лично и частично опубликованы, в т. ч. в соавторстве (вклад автора более 80 %) в [21; 24; 25; 26; 28; 29].

3. Разработан алгоритм формирования признакового пространства, реализующий отображение из пятимерного пространства исходных сенсорных измерений в восьмимерное расширенное пространство путем конструирования трёх производных признаков на основе физики теплообменных процессов

(бинарный индикатор потери экранирующего слоя, интегральный параметр гелиевого контура, интегральный параметр азотного контура). Количественная валидация методом аддитивной декомпозиции подтвердила, что три производных признака обеспечивают 78 % суммарного вклада в решения модели. Разработан алгоритм интеллектуальной поддержки принятия решений, включающий модель классификации состояний (случайный лес, 200 деревьев, $F_1 = 0,925$ при стратифицированной пятикратной кросс-валидации с коэффициентом вариации 2,3 %) и алгоритм представления результатов, обеспечивающий формирование интерпретируемой рекомендации для оператора с указанием факторов, определивших решение модели. Построена функциональная модель системы поддержки принятия решений в четырёхуровневой архитектуре развертывания, описывающая технологический процесс обработки информации в штатном режиме и в режиме адаптации. Предложен алгоритм адаптации модели на эксплуатационных данных с автоматической разметкой, двухкритериальной валидацией (F_1 и полнота) и развертыванием через беспроводной канал с верификацией целостности. Результаты получены автором лично и частично опубликованы, в т. ч. в соавторстве (вклад автора более 80 %) в [21; 24; 27; 28; 29].

4. Выполнена программная реализация в виде двух зарегистрированных программных продуктов (свидетельства о государственной регистрации программ для ЭВМ № 2025614055 [125] и № 2025684788 [126]). Подтверждена совместимость с ресурсными ограничениями бортового контроллера (80–120 КБ памяти при ограничении 256 КБ, время полного цикла обработки не более 20 мс при ограничении 50 мс). По данным сенсорных систем криогенных контейнеров экспериментальная оценка показала следующее: модель в расширенном признаковом пространстве достигает $F_1 = 0,925 \pm 0,021$, причём статистическая значимость преимущества подтверждена критерием Уилкоксона ($W = 15$, $p = 0,031$). Переобучение не выявлено – это подтверждено на независимой выборке из 185 наблюдений ($F_1 = 0,870$, относительное отклонение в $-5,9$ % от результата кросс-валидации ($0,925$) и $+1,5$ % от значения F_1 на тестовой выборке исходного пространства $R^5 = 0,857$). По сравнению с действующим ручным контролем

достигнуто повышение F_1 -меры с 0,46 до 0,89, сокращение времени реакции оператора с 204 до 2,3 минуты, снижение доли ложных срабатываний с 4,9 % до 0,6 %, а также рост полноты обнаружения с 0,58 до 0,86. Четыре цикла адаптации за 18 месяцев эксплуатации подтвердили работоспособность алгоритма адаптации: значение F_1 фактически не опускалось ниже 0,880 при установленном пороге 0,875, при этом рост обучающей выборки с 890 до 1320 наблюдений и двойной критерий валидации обеспечили монотонность качества системы. Программный комплекс внедрён в промышленную эксплуатацию на парке криогенных контейнеров: снижение доли ложных тревог с 4,9 % до 0,6 % (в 8,2 раза), время реакции оператора сократилось с 204 до 2,3 минуты (в 89 раз), экономический эффект оценивается в 7–10 %. Внедрение результатов на промышленных предприятиях и в учебный процесс подтверждено соответствующими актами (см. Приложение А), а программные продукты зарегистрированы в установленном порядке (см. Приложение А). Результаты получены автором лично и частично опубликованы, в т. ч. в соавторстве (вклад автора более 80 %) в [20; 22; 25; 28], а также подтверждены свидетельствами о государственной регистрации программ для ЭВМ [125; 126].

Таким образом, все поставленные в диссертационном исследовании задачи решены, а основная цель – повышение качества и оперативности обработки информации интеллектуального управления многослойной криогенной системой за счёт разработки моделей и алгоритмов на основе многокритериальной оптимизации с ограничениями – достигнута.

Направлениями дальнейших исследований являются расширение алгоритмов формирования признакового пространства на многокомпонентные криогенные системы с числом контролируемых сред более двух, разработка методов адаптации модели в реальном времени без разделения на штатный режим и режим обслуживания, исследование применимости разработанных подходов к смежным классам технических объектов с ограниченными вычислительными ресурсами (промышленные системы управления, мобильные диагностические комплексы), а

также интеграция механизмов прогнозирования состояния на основе временных рядов для перехода от реактивного к упреждающему управлению.

Все результаты, представленные в диссертационной работе, получены автором лично и были опубликованы, в том числе в соавторстве (вклад автора более 80 %), в рецензируемых научных изданиях, рекомендованных ВАК Российской Федерации [21; 23; 24; 25; 26; 28; 29; 31; 32], а также в материалах международных и всероссийских научных конференций [20; 22; 27; 30]. По результатам исследования получены два свидетельства о государственной регистрации программ для ЭВМ № 2025614055 [125] и № 2025684788 [126].

Список сокращений и условных обозначений

В данной диссертационной работе применяются следующие сокращения:

АСУ	– автоматизированная система управления
БД	– база данных
ВАК	– Высшая аттестационная комиссия при Министерстве науки и высшего образования Российской Федерации
ГОСТ	– государственный стандарт
ИГХТУ	– Ивановский государственный химико-технологический университет
КБ	– килобайт
МКС	– многослойная криогенная система
МЭВИ	– многослойная экранно-вакуумная изоляция
ПЛК	– программируемый логический контроллер
СППР	– система поддержки принятия решений
ТО	– техническое обслуживание
ФГБОУ ВО	– федеральное государственное бюджетное образовательное учреждение высшего образования
CV	– coefficient of variation (коэффициент вариации)
F1	– гармоническое среднее точности и полноты (F1-мера)
FN	– false negative (ложноотрицательный результат)
FP	– false positive (ложноположительный результат)
IQR	– interquartile range (межквартильный размах)
ROC	– Receiver Operating Characteristic (рабочая характеристика приёмника)
SHAP	– SHapley Additive exPlanations (аддитивная декомпозиция по Шепли)
STM32	– семейство микроконтроллеров на базе ARM Cortex (производитель STMicroelectronics)
SVM	– Support Vector Machine (метод опорных векторов)
TN	– true negative (истинно отрицательный результат)
TP	– true positive (истинно положительный результат)

Список литературы

1. ISO 5725-6:2002. Accuracy (trueness and precision) of measurement methods and results. Part 6: Use in practice of accuracy values. – Geneva : ISO, 2002. – 42 p.
2. ISO/IEC 25010:2011. Systems and software engineering – Systems and software quality models. – Geneva : ISO/IEC, 2011. – 34 p.
3. ISO/IEC/IEEE 42010:2011. Systems and software engineering – Architecture description. – Geneva : ISO/IEC/IEEE, 2011. – 45 p.
4. ГОСТ Р 27.302-2009. Надежность в технике. Анализ видов, последствий и критичности отказов (FMEA). – Введ. 2009-12-15. – М. : Стандартинформ, 2010. – 24 с.
5. ГОСТ Р 7.0.5-2008. Библиографическая ссылка. Общие требования и правила составления. – Введ. 2008-10-16. – М. : Стандартинформ, 2008. – 50 с.
6. Айвазян, С. А. Прикладная статистика. Основы моделирования и первичная обработка данных / С. А. Айвазян, И. С. Енюков, Л. Д. Мешалкин. – М. : Финансы и статистика, 1983. – 471 с.
7. Архаров, А. М. Криогенные системы. Основы теории и расчета / А. М. Архаров, И. В. Марфенина, Е. И. Микулин. – М. : Энергия, 1988. – 463 с.
8. Астраханцева, И. А. Дискретная стохастическая модель гидродинамики потока / И. А. Астраханцева, С. П. Бобков // Моделирование систем и процессов. – 2023. – Т. 16, № 2. – С. 7–14. – DOI: 10.12737/2219-0767-2023-16-2-7-14. – EDN BYGGKR.
9. Афанасьев, В. Н. Системный анализ и методы принятия решений / В. Н. Афанасьев, В. Д. Колмановский, В. Р. Носов. – М. : Высшая школа, 2004. – 367 с.
10. Барсегян, А. А. Методы и модели анализа данных: OLAP и Data Mining / А. А. Барсегян, М. С. Куприянов, В. В. Степаненко, И. И. Холод. – СПб. : БХВ-Петербург, 2004. – 336 с. – ISBN 5-94157-522-8.
11. Беляков, В. П. Криогенная техника и технология / В. П. Беляков. – М. : Энергоиздат, 1982. – 272 с.

12. Бобков, С. П. Имитационное моделирование процесса электросинтеза озона / С. П. Бобков, И. А. Астраханцева, Э. Г. Галиаскаров, Е. С. Бобкова // Современные наукоемкие технологии. Региональное приложение. – 2024. – № 2(78). – С. 59–67. – DOI: 10.6060/snt.20247802.0008. – EDN RFDSCM.
13. Бобков, С. П. Использование вероятностных клеточных автоматов для моделирования течения жидкости / С. П. Бобков, И. А. Астраханцева // Современные наукоемкие технологии. Региональное приложение. – 2022. – № 2(70). – С. 47–54. – DOI: 10.6060/snt.20227002.0006. – EDN ZMAHGM.
14. Бобков, С. П. Моделирование процесса теплопроводности с использованием систем клеточных автоматов / С. П. Бобков, Э. Г. Галиаскаров // Программные продукты и системы. – 2020. – № 4. – С. 641–650. – DOI: 10.15827/0236-235X.132.641-650. – EDN RFIIRL.
15. Бобков, С. П. Применение системного подхода при разработке математических моделей / С. П. Бобков, И. А. Астраханцева, Э. Г. Галиаскаров // Современные наукоемкие технологии. Региональное приложение. – 2021. – № 1(65). – С. 66–71. – DOI: 10.6060/snt.20216501.0008. – EDN KOXZWY.
16. Бурков, В. Н. Задачи управления в социальных и экономических системах / В. Н. Бурков, Д. А. Новиков // Автоматика и телемеханика. – 2005. – № 3. – С. 3–25.
17. Вапник, В. Н. Восстановление зависимостей по эмпирическим данным / В. Н. Вапник. – М. : Наука, 1979. – 447 с.
18. Васильев, С. Н. От классических задач регулирования к интеллектуальному управлению / С. Н. Васильев // Известия Российской академии наук. Теория и системы управления. – 2001. – № 1. – С. 5–21.
19. Гаврилова, Т. А. Базы знаний интеллектуальных систем / Т. А. Гаврилова, В. Ф. Хорошевский. – СПб. : Питер, 2000. – 384 с. – ISBN 5-272-00071-4.
20. Горев, С. В. Адаптивная система интеллектуальной поддержки принятия решений управления многослойной криогенной системой / С. В. Горев, И. А. Астраханцева // Сборник статей по материалам международной научно-практической конференции «Теория и практика применения вычислительных и

информационных технологий в отраслевых системах». – Москва, 13–14.03.2026. – С. 20–26.

21. Горев, С. В. Интеграция методов линейной регрессии и случайного леса в системы интеллектуальной поддержки управления криогенными транспортными системами / С. В. Горев, И. А. Астраханцева, Т. Е. Котенев, Р. Г. Астраханцев, П. Н. Грименицкий // Известия высших учебных заведений. Серия: Экономика, финансы и управление производством. – 2024. – № 3(61). – С. 81–90.

22. Горев, С. В. Интеллектуальные многослойные криогенные системы: энергоэффективность и надежность в «экономике льда и снега» / С. В. Горев, Р. Г. Астраханцев, И. А. Астраханцева // Новые вызовы и форматы устойчивого экономического развития в период неопределенности: российский и зарубежный опыт : сборник научных статей по результатам V международной научно-практической конференции и XI научно-практической конференции / под ред. М. Ю. Шерешевой, И. И. Савельевой. – Москва : Экономический факультет МГУ имени М. В. Ломоносова, 2026. – С. 145–154.

23. Горев, С. В. Математические модели для оптимизации машиночитаемых регулятивных систем / С. В. Горев, Е. Н. Морозов // Известия высших учебных заведений. Серия: Экономика, финансы и управление производством. – 2023. – № 4(58). – С. 71–78.

24. Горев, С. В. Метод градиентного бустинга при прогнозировании управленческих решений в многослойной криогенной системе / С. В. Горев, И. А. Астраханцева, Т. Е. Котенев [и др.] // Современные наукоемкие технологии. Региональное приложение. – 2024. – № 2(78). – С. 50–58.

25. Горев, С. В. Методология интеллектуальной поддержки принятия решений при эксплуатации многослойных криогенных систем / С. В. Горев // Известия высших учебных заведений. Серия: Экономика, финансы и управление производством. – 2026. – № 1(67). – С. 146–157.

26. Горев, С. В. Методы искусственного интеллекта в управлении многослойной криогенной системой с вакуумной изоляцией и азотным экраном /

С. В. Горев, И. А. Астраханцева, Т. Е. Котенев [и др.] // Современные наукоемкие технологии. Региональное приложение. – 2024. – № 1(77). – С. 50–59.

27. Горев, С. В. Многослойная криогенная система как объект структурного, управленческого и адаптивного моделирования в системном анализе / С. В. Горев, И. А. Астраханцева // Имитационное моделирование. Теория и практика (ИММОД-2025): Труды конференции, Санкт-Петербург, 15–17.10.2025 – Санкт-Петербург : АО «ЦТСС», 2025. – С. 652–658.

28. Горев, С. В. Модели и алгоритмы интеллектуального управления многослойной криогенной системой / С. В. Горев, И. А. Астраханцева // Современные наукоемкие технологии. Региональное приложение. – 2026. – № 2(86). – С. 59–70.

29. Горев, С. В. Оптимизация эксплуатации многослойных криогенных систем с применением методов машинного обучения и стандартизированных протоколов внедрения / С. В. Горев, И. А. Астраханцева, Т. Е. Котенев, Р. Г. Астраханцев // Современные наукоемкие технологии. Региональное приложение. – 2025. – № 2(82). – С. 59–70.

30. Горев, С. В. Простые модели машинного обучения для прогнозирования и поддержки управленческих решений в многослойных криогенных системах / С. В. Горев, И. А. Астраханцева // Прикладной искусственный интеллект: перспективы и риски: Сборник докладов II Международной научной конференции, Санкт-Петербург, 21.10.2025 – Санкт-Петербург : Санкт-Петербургский государственный университет аэрокосмического приборостроения, 2025. – С. 197–202.

31. Горев, С. В. Системный подход к анализу фрактальной природы сложных технических систем / С. В. Горев, И. А. Астраханцева, Р. Г. Астраханцев // Известия высших учебных заведений. Серия: Экономика, финансы и управление производством. – 2023. – № 3(57). – С. 89–97.

32. Горев, С. В. Фрактальный анализ в оценке эффективности и надежности сложных технических систем / С. В. Горев, И. А. Астраханцева, Р. Г. Астраханцев

// Современные наукоемкие технологии. Региональное приложение. – 2023. – № 4(76). – С. 60–68.

33. Городецкий, В. И. Многоагентные системы: современное состояние исследований и перспективы применения / В. И. Городецкий // Новости искусственного интеллекта. – 2004. – № 1. – С. 44–59.

34. Гудфеллоу, И. Г. Глубокое обучение / И. Г. Гудфеллоу, Й. Бенджио, А. Курвилль. – М. : ДМК Пресс, 2018. – 800 с. – ISBN 978-5-97060-618-6.

35. Емельянов, В. В. Теория и практика эволюционного моделирования / В. В. Емельянов, В. В. Курейчик, В. М. Курейчик. – М. : Физматлит, 2003. – 432 с. – ISBN 5-9221-0337-7.

36. Загоруйко, Н. Г. Прикладные методы анализа данных и знаний / Н. Г. Загоруйко. – Новосибирск : ИМ СО РАН, 1999. – 270 с. – ISBN 5-86134-060-9.

37. Зарубин, В. С. Математическое моделирование в технике / В. С. Зарубин. – М. : Изд-во МГТУ им. Н. Э. Баумана, 2003. – 495 с.

38. Захаров, В. Н. Интеллектуальные системы управления: проблемы и перспективы / В. Н. Захаров // Известия Российской академии наук. Теория и системы управления. – 2020. – № 1. – С. 3–14.

39. Качала, В. В. Основы теории систем и системного анализа / В. В. Качала. – 2-е изд. – М. : Горячая линия – Телеком, 2012. – 210 с.

40. Колмогоров, А. Н. Три подхода к определению понятия «количество информации» / А. Н. Колмогоров // Проблемы передачи информации. – 1965. – Т. 1, № 1. – С. 3–11.

41. Круглов, В. В. Искусственные нейронные сети. Теория и практика / В. В. Круглов, В. В. Борисов. – М. : Горячая линия – Телеком, 2002. – 382 с. – ISBN 5-93517-031-0.

42. Ларичев, О. И. Теория и методы принятия решений / О. И. Ларичев. – М. : Логос, 2000. – 296 с.

43. Моисеев, Н. Н. Математические задачи системного анализа / Н. Н. Моисеев. – М. : Наука, 1981. – 488 с.

44. Монахов, М. Ю. Определение контекстной тональности сообщений в задачах информационного влияния. Часть 1 / М. Ю. Монахов, Ю. М. Монахов, Д. В. Мазурок, Е. А. Матвеева // Проектирование и технология электронных средств. – 2023. – № 2. – С. 7–11.
45. Новиков, Д. А. Теория управления организационными системами / Д. А. Новиков. – 3-е изд. – М. : Физико-математическая литература, 2012. – 604 с.
46. Осипов, Г. С. Методы искусственного интеллекта / Г. С. Осипов. – М. : Физматлит, 2011. – 296 с. – ISBN 978-5-9221-1323-6.
47. Перегудов, Ф. И. Основы системного анализа / Ф. И. Перегудов, Ф. П. Тарасенко. – 3-е изд. – Томск : Изд-во НТЛ, 2001. – 396 с. – ISBN 5-89503-115-3.
48. Попов, Э. В. Экспертные системы: решение неформализованных задач в диалоге с ЭВМ / Э. В. Попов. – М. : Наука, 1987. – 288 с.
49. Поспелов, Д. А. Ситуационное управление: теория и практика / Д. А. Поспелов. – М. : Наука, 1986. – 288 с.
50. Растрингин, Л. А. Адаптация сложных систем / Л. А. Растрингин. – Рига : Зинатне, 1981. – 375 с.
51. Рутковская, Д. Нейронные сети, генетические алгоритмы и нечеткие системы / Д. Рутковская, М. Пилиньский, Л. Рутковский. – М. : Горячая линия – Телеком, 2006. – 452 с.
52. Свиридюк, Г. А. Линейные уравнения типа Соболева и вырожденные полугруппы операторов / Г. А. Свиридюк, В. Е. Федоров. – Berlin : De Gruyter, 2003. – 216 с.
53. Советов, Б. Я. Моделирование систем / Б. Я. Советов, С. А. Яковлев. – М. : Высшая школа, 2001. – 343 с.
54. Тарасов, В. Б. От многоагентных систем к интеллектуальным организациям / В. Б. Тарасов. – М. : Эдиториал УРСС, 2002. – 352 с.
55. Тимохин, М. Ю. Искусственный интеллект и теория принятия решений: современные тенденции / М. Ю. Тимохин, В. Ю. Шаранин // Инженерный вестник Дона. – 2023. – № 10 (106). – С. 33–44.

56. Флач, П. Машинное обучение. Наука и искусство построения алгоритмов, которые извлекают знания из данных / П. Флач ; пер. с англ. А. А. Слинкина. – М. : ДМК Пресс, 2015. – 400 с. – ISBN 978-5-97060-273-7.
57. Хайкин, С. Нейронные сети: полный курс / С. Хайкин ; пер. с англ. – 2-е изд. – М. : Вильямс, 2006. – 1104 с.
58. Юсупов, Р. М. Интеллектуальное управление в активных системах / Р. М. Юсупов, Б. В. Соколов // Труды СПИИРАН. – 2010. – Вып. 15. – С. 7–30.
59. Abid, A. Concrete Autoencoders for Differentiable Feature Selection and Reconstruction / A. Abid, M. F. Balin, J. Zou // Proceedings of the 36th International Conference on Machine Learning (ICML). – 2019. – P. 1–9.
60. Alpaydin, E. Introduction to Machine Learning / E. Alpaydin. – 4th ed. – Cambridge, MA : MIT Press, 2020. – 712 p. – ISBN 978-0-262-04379-3.
61. Barron, R. F. Cryogenic Systems / R. F. Barron. – 2nd ed. – New York : Oxford University Press, 1985. – 528 p.
62. Bengio, Y. Learning deep architectures for AI / Y. Bengio // Foundations and Trends in Machine Learning. – 2009. – Vol. 2, No. 1. – P. 1–127. – DOI: 10.1561/22000000006.
63. Bishop, C. M. Pattern Recognition and Machine Learning / C. M. Bishop. – New York : Springer, 2006. – 738 p. – ISBN 978-0387310732.
64. Breiman, L. Random forests / L. Breiman // Machine Learning. – 2001. – Vol. 45, No. 1. – P. 5–32. – DOI: 10.1023/A:1010933404324.
65. Camacho, E. F. Model Predictive Control / E. F. Camacho, C. Bordons. – 2nd ed. – London : Springer, 2004. – 405 p. – ISBN 978-1852336943.
66. Caruana, R. An empirical comparison of supervised learning algorithms / R. Caruana, A. Niculescu-Mizil // Proceedings of the 23rd International Conference on Machine Learning (ICML). – 2006. – P. 161–168.
67. Chen, T. XGBoost: A scalable tree boosting system / T. Chen, C. Guestrin // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '16). – San Francisco, CA, USA : ACM, 2016. – P. 785–794. – DOI: 10.1145/2939672.2939785.

68. Christ, M. Time Series Feature Extraction on Basis of Scalable Hypothesis Tests (tsfresh) / M. Christ, N. Braun, J. Neuffer, A. W. Kempa-Liehr // *Neurocomputing*. – 2018. – Vol. 307. – P. 72–77. – DOI: 10.1016/j.neucom.2018.03.067.
69. Cortes, C. Support-Vector Networks / C. Cortes, V. Vapnik // *Machine Learning*. – 1995. – Vol. 20, No. 3. – P. 273–297. – DOI: 10.1023/A:1022627411411.
70. Daigle, M. J. Model-Based Prognostics With Concurrent Damage Progression Processes / M. J. Daigle, K. Goebel // *IEEE Transactions on Systems, Man, and Cybernetics: Systems and Humans*. – 2013. – Vol. 43, No. 3. – P. 535–546. – DOI: 10.1109/TSMCA.2012.2207109.
71. Dietterich, T. G. Ensemble Methods in Machine Learning / T. G. Dietterich // *Multiple Classifier Systems*. – 2000. – Vol. 1857. – P. 1–15. – DOI: 10.1007/3-540-45014-9-1.
72. Feurer, M. Efficient and Robust Automated Machine Learning / M. Feurer, A. Klein, K. Eggenberger [et al.] // *Advances in Neural Information Processing Systems (NeurIPS)*. – 2015. – Vol. 28. – P. 2962–2970.
73. Flynn, T. M. *Cryogenic Engineering. Revised and Expanded* / T. M. Flynn. – 2nd ed. – Boca Raton : CRC Press, 2004. – 910 p.
74. Franklin, G. F. *Feedback Control of Dynamic Systems* / G. F. Franklin, J. D. Powell, A. Emami-Naeini. – 8th ed. – Boston : Pearson, 2020. – 848 p. – ISBN 978-0136747377.
75. Friedman, J. H. Stochastic gradient boosting / J. H. Friedman // *Computational Statistics & Data Analysis*. – 2002. – Vol. 38, No. 4. – P. 367–378.
76. Gebraeel, N. Residual life predictions from vibration-based degradation signals: a neural network approach / N. Gebraeel, M. Lawley, R. Liu, V. Parmeshwaran // *IEEE Transactions on Industrial Electronics*. – 2004. – Vol. 51, No. 3. – P. 694–700.
77. Goodfellow, I. *Deep Learning* / I. Goodfellow, Y. Bengio, A. Courville. – Cambridge, MA : MIT Press, 2016. – 800 p. – ISBN 978-0262035613.
78. Hastie, T. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* / T. Hastie, R. Tibshirani, J. Friedman. – 2nd ed. – New York : Springer, 2009. – 745 p. – ISBN 978-0387848587.

79. He, X. AutoML: A survey of the state-of-the-art / X. He, K. Zhao, X. Chu // Knowledge-Based Systems. – 2021. – Vol. 212. – P. 106622. – DOI: 10.1016/j.knosys.2020.106622.
80. Heng, A. Rotating machinery prognostics: State of the art, challenges and opportunities / A. Heng, S. Zhang, A. C. C. Tan, J. Mathew // Mechanical Systems and Signal Processing. – 2009. – Vol. 23, No. 3. – P. 724–739.
81. Hinton, G. E. Reducing the dimensionality of data with neural networks / G. E. Hinton, R. R. Salakhutdinov // Science. – 2006. – Vol. 313, No. 5786. – P. 504–507. – DOI: 10.1126/science.1127647.
82. Hochreiter, S. Long Short-Term Memory / S. Hochreiter, J. Schmidhuber // Neural Computation. – 1997. – Vol. 9, No. 8. – P. 1735–1780. – DOI: 10.1162/neco.1997.9.8.1735.
83. Horn, F. The autofeat Python Library for Automated Feature Engineering and Selection / F. Horn, R. Pack, M. Rieger. – arXiv:1901.07329. – 2019. – URL: <https://arxiv.org/abs/1901.07329> (дата обращения: 04.09.2025).
84. Hutter, F. Automated Machine Learning: Methods, Systems, Challenges / F. Hutter, L. Kotthoff, J. Vanschoren (eds.). – Cham : Springer, 2019. – 219 p.
85. Isermann, R. Fault-diagnosis systems: An introduction from fault detection to fault tolerance / R. Isermann. – Berlin : Springer, 2006. – 500 p. – ISBN 978-3540246718.
86. Jordan, M. I. Machine learning: Trends, perspectives, and prospects / M. I. Jordan, T. M. Mitchell // Science. – 2015. – Vol. 349, No. 6245. – P. 255–260. – DOI: 10.1126/science.aaa8415.
87. Kanter, J. M. Deep Feature Synthesis: Towards Automating Data Science Endeavors / J. M. Kanter, K. Veeramachaneni // Proceedings of the 2015 IEEE International Conference on Data Science and Advanced Analytics (DSAA). – Paris : IEEE, 2015. – P. 1–10. – DOI: 10.1109/DSAA.2015.7344858.
88. Karniadakis, G. E. Physics-informed machine learning / G. E. Karniadakis, I. G. Kevrekidis, L. Lu [et al.] // Nature Reviews Physics. – 2021. – Vol. 3, No. 6. – P. 422–440. – DOI: 10.1038/s42254-021-00314-5.

89. Ke, G. LightGBM: A Highly Efficient Gradient Boosting Decision Tree / G. Ke, Q. Meng, T. Finley [et al.] // *Advances in Neural Information Processing Systems (NeurIPS)*. – 2017. – Vol. 30. – P. 3146–3154.
90. Kingma, D. P. Adam: A Method for Stochastic Optimization / D. P. Kingma, J. Ba. – arXiv:1412.6980. – 2014. – URL: <https://arxiv.org/abs/1412.6980> (дата обращения: 04.09.2025).
91. Kohavi, R. A study of cross-validation and bootstrap for accuracy estimation and model selection / R. Kohavi // *Proceedings of the 14th International Joint Conference on Artificial Intelligence (IJCAI)*. – 1995. – P. 1137–1143.
92. LeCun, Y. Deep Learning / Y. LeCun, Y. Bengio, G. Hinton // *Nature*. – 2015. – Vol. 521, No. 7553. – P. 436–444. – DOI: 10.1038/nature14539.
93. Liao, L. A hybrid framework combining data-driven and model-based methods for system remaining useful life prediction / L. Liao, F. Kottig // *Applied Soft Computing*. – 2016. – Vol. 44. – P. 191–199. – DOI: 10.1016/j.asoc.2016.03.013.
94. Lundberg, S. M. A Unified Approach to Interpreting Model Predictions / S. M. Lundberg, S.-I. Lee // *Advances in Neural Information Processing Systems (NeurIPS)*. – 2017. – Vol. 30. – P. 4765–4774.
95. Mesarovic, M. D. *Theory of Hierarchical, Multilevel, Systems* / M. D. Mesarovic, D. Macko, Y. Takahara. – New York : Academic Press, 1970. – 294 p.
96. Mnih, V. Human-Level Control through Deep Reinforcement Learning / V. Mnih [et al.] // *Nature*. – 2015. – Vol. 518, No. 7540. – P. 529–533. – DOI: 10.1038/nature14541.
97. Molnar, C. *Interpretable Machine Learning: A Guide for Making Black Box Models Explainable* / C. Molnar. – 2nd ed. – [S. l.] : Leanpub, 2022. – 317 p.
98. Murphy, K. P. *Machine Learning: A Probabilistic Perspective* / K. P. Murphy. – Cambridge, MA : MIT Press, 2012. – 1024 p. – ISBN 978-0-262-01808-6.
99. Ogata, K. *Modern Control Engineering* / K. Ogata. – 5th ed. – Boston : Prentice Hall, 2010. – 912 p. – ISBN 978-0136156734.

100. Pan, S. J. A Survey on Transfer Learning / S. J. Pan, Q. Yang // IEEE Transactions on Knowledge and Data Engineering. – 2010. – Vol. 22, No. 10. – P. 1345–1359. – DOI: 10.1109/TKDE.2009.191.
101. Pedregosa, F. Scikit-learn: Machine Learning in Python / F. Pedregosa, G. Varoquaux, A. Gramfort [et al.] // Journal of Machine Learning Research. – 2011. – Vol. 12. – P. 2825–2830.
102. Pezzetti, M. Control of large helium cryogenic systems: a case study on CERN LHC / M. Pezzetti // EPJ Techniques and Instrumentation. – 2021. – Vol. 8, Article 6. – DOI: 10.1140/epjti/s40485-021-00063-w.
103. Prokhorenkova, L. CatBoost: unbiased boosting with categorical features / L. Prokhorenkova, G. Gusev, A. Vorobev [et al.] // Advances in Neural Information Processing Systems (NeurIPS). – 2018. – Vol. 31. – P. 6638–6648.
104. Quinlan, J. R. Induction of decision trees / J. R. Quinlan // Machine Learning. – 1986. – Vol. 1, No. 1. – P. 81–106. – DOI: 10.1023/A:1022643204877.
105. Raissi, M. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems / M. Raissi, P. Perdikaris, G. E. Karniadakis // Journal of Computational Physics. – 2019. – Vol. 378. – P. 686–707. – DOI: 10.1016/j.jcp.2018.10.045.
106. Ribeiro, M. T. «Why Should I Trust You?» Explaining the Predictions of Any Classifier / M. T. Ribeiro, S. Singh, C. Guestrin // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '16). – New York : ACM, 2016. – P. 1135–1144. – DOI: 10.1145/2939672.2939835.
107. Russell, S. Artificial Intelligence: A Modern Approach / S. Russell, P. Norvig. – 4th ed. – Hoboken : Pearson, 2021. – 1132 p. – ISBN 978-0134610993.
108. Saha, B. Prognostics methods for battery health monitoring using a Bayesian framework / B. Saha, K. Goebel, S. Poll, J. Christophersen // IEEE Transactions on Instrumentation and Measurement. – 2009. – Vol. 58, No. 2. – P. 291–296. – DOI: 10.1109/TIM.2008.2005965.

109. Saxena, A. Metrics for offline evaluation of prognostic performance / A. Saxena, J. Celaya, B. Saha [et al.] // International Journal of Prognostics and Health Management. – 2010. – Vol. 1, No. 1. – P. 1–20.
110. Sculley, D. Hidden technical debt in machine learning systems / D. Sculley, G. Holt, D. Golovin [et al.] // Advances in Neural Information Processing Systems (NeurIPS). – 2015. – Vol. 28. – P. 2503–2511.
111. Shannon, C. E. A Mathematical Theory of Communication / C. E. Shannon // The Bell System Technical Journal. – 1948. – Vol. 27, No. 3. – P. 379–423. – DOI: 10.1002/j.1538-7305.1948.tb01338.x.
112. Si, X.-S. Remaining useful life estimation: A review on the statistical data driven approaches / X.-S. Si, W. Wang, C.-H. Hu, D.-H. Zhou // European Journal of Operational Research. – 2011. – Vol. 213, No. 1. – P. 1–14. – DOI: 10.1016/j.ejor.2010.11.018.
113. Sutton, R. S. Reinforcement learning: An introduction / R. S. Sutton, A. G. Barto. – 2nd ed. – Cambridge, MA : MIT Press, 2018. – 528 p. – ISBN 978-0262039246.
114. Sze, V. Efficient Processing of Deep Neural Networks: A Tutorial and Survey / V. Sze, Y.-H. Chen, T.-J. Yang, J. Emer // Proceedings of the IEEE. – 2017. – Vol. 105, No. 12. – P. 2295–2329. – DOI: 10.1109/JPROC.2017.2761740.
115. Van Sciver, S. W. Helium Cryogenics / S. W. Van Sciver. – 2nd ed. – New York : Springer, 2012. – 470 p. – ISBN 978-1461430445.
116. Vaswani, A. Attention is All You Need / A. Vaswani, N. Shazeer, N. Parmar [et al.] // Advances in Neural Information Processing Systems (NeurIPS). – 2017. – Vol. 30. – P. 5998–6008.
117. von Bertalanffy, L. General System Theory: Foundations, Development, Applications / L. von Bertalanffy. – Rev. ed. – New York : George Braziller, 1968. – 289 p. – ISBN 978-0807604533.
118. Warden, P. TinyML: Machine Learning with TensorFlow Lite on Microcontrollers / P. Warden, D. Situnayake. – Sebastopol, CA : O'Reilly Media, 2019. – 504 p. – ISBN 978-1492052043.

119. Watkins, C. J. C. H. Q-Learning / C. J. C. H. Watkins, P. Dayan // Machine Learning. – 1992. – Vol. 8, No. 3–4. – P. 279–292. – DOI: 10.1007/BF00992698.

120. Wolpert, D. H. No free lunch theorems for optimization / D. H. Wolpert, W. G. Macready // IEEE Transactions on Evolutionary Computation. – 1997. – Vol. 1, No. 1. – P. 67–82. – DOI: 10.1109/4235.585893.

121. Woodcraft, A. L. Recommended values for the thermal conductivity of aluminium of different purities in the cryogenic to room temperature range, and a comparison with copper / A. L. Woodcraft // Cryogenics. – 2005. – Vol. 45, No. 9. – P. 626–636. – DOI: 10.1016/j.cryogenics.2005.05.008.

122. Zheng, A. Feature Engineering for Machine Learning / A. Zheng, A. Casari. – Beijing : O'Reilly Media, 2018. – 242 p. – ISBN 978-1-491-97060-8.

123. Zoller, M. A. Benchmark and Survey of Automated Machine Learning Frameworks / M. A. Zoller, M. F. Huber // Journal of Artificial Intelligence Research. – 2021. – Vol. 70. – P. 409–472.

124. Zoph, B. Neural Architecture Search with Reinforcement Learning / B. Zoph, Q. V. Le. – arXiv:1611.01578. – 2016. – URL: <https://arxiv.org/abs/1611.01578> (дата обращения: 04.09.2025).

125. Свидетельство о государственной регистрации программы для ЭВМ № 2025614055 Российская Федерация. Программа интеллектуальной поддержки принятия решений для управления многослойной криогенной системой с использованием методов машинного обучения : № 2025612232 : заявл. 07.02.2025 : опубл. 18.02.2025 / С. В. Горев, И. А. Астраханцева.

126. Свидетельство о государственной регистрации программы для ЭВМ № 2025684788 Российская Федерация. Программа для сбора и обработки данных многослойной криогенной системы : № 2025683896 : заявл. 20.08.2025 : опубл. 17.09.2025 / С. В. Горев.

Приложение А

(справочное)

Акты об использовании и внедрении результатов диссертационного исследования

Акты об использовании и внедрении результатов диссертационного исследования, а также свидетельства о государственной регистрации программ для ЭВМ:

- Акт о внедрении результатов диссертационного исследования в систему управления парком криогенных контейнеров ООО «ИнфраПро», г. Москва;
- Акт о внедрении результатов диссертационного исследования в систему мониторинга промышленного оборудования АО «Инвест-Альянс», г. Москва;
- Акт о внедрении результатов диссертационного исследования в технологические процессы АО «Ивхимпром», г. Иваново;
- Акт об использовании в учебном процессе результатов диссертационной работы при преподавании дисциплин ИГХТУ;
- Свидетельство о государственной регистрации программы для ЭВМ № 2025614055 «Программа интеллектуальной поддержки принятия решений для управления многослойной криогенной системой»;
- Свидетельство о государственной регистрации программы для ЭВМ № 2025684788 «Программа для сбора и обработки данных многослойной криогенной системы».

В Диссертационный Совет

АКТ

о внедрении результатов диссертационного исследования

Горева Сергея Владимировича

Настоящим подтверждаем, что результаты диссертационного исследования Горева Сергея Владимировича на тему «Модели и алгоритмы интеллектуального управления многослойной криогенной системой» использованы в производственной деятельности ООО «ИнфраПро» при организации эксплуатации транспортных криогенных контейнеров-цистерн.

В ООО «ИнфраПро» внедрены разработанные в ходе диссертационного исследования модели и алгоритмы интеллектуального управления многослойной криогенной системой. Внедрение включает математическую модель классификации состояний криогенной системы, алгоритм формирования признакового пространства на основе физических соотношений между параметрами контролируемых сред, алгоритм интеллектуальной поддержки принятия решений с интерпретируемым представлением результатов и алгоритм периодической адаптации модели на эксплуатационных данных. Модели и алгоритмы реализованы в составе двух программ, прошедших государственную регистрацию в Федеральной службе по интеллектуальной собственности (свидетельства № 2025614055 от 18.02.2025 и № 2025684788 от 17.09.2025).

На эксплуатационных данных ООО «ИнфраПро» проведена экспериментальная оценка разработанных моделей и алгоритмов. Достигнута F1-мера классификации 0,925 при полном отсутствии пропущенных критических состояний. Среднее время реакции оператора на критические состояния сократилось со 204 до 2,3 минуты.

Результаты диссертационного исследования С.В. Горева положительно отражаются на качестве принимаемых управленческих решений и безопасности эксплуатации криогенного оборудования ООО «ИнфраПро».

Генеральный директор УК



/Дмитриев И.В./

Акционерное общество «Инвест-Альянс»

ИНН 7716712361 КПП 770901001 ОГРН 1127746212989

109028, г. Москва, Хохловский переулок, дом 15, помещение I, комната 4

Тел.: (8216) 75-07-12; email: at@invest-a.ru, tz@invest-a.ru, md@invest-a.ru, tender@invest-a.ru

Исх. № 84 /11 от
15.04.2026

В Диссертационный Совет

АКТ

о внедрении результатов диссертационного исследования

Горева Сергея Владимировича

Настоящим подтверждаем, что результаты диссертационного исследования Горевы Сергея Владимировича на тему «Модели и алгоритмы интеллектуального управления многослойной криогенной системой» использованы в нашей организации при эксплуатации промышленного оборудования.

На предприятии внедрен разработанный в ходе диссертационного исследования С.В. Горевы алгоритм периодической адаптации модели классификации состояний технической системы. Алгоритм обеспечивает автоматическое переобучение модели на накопленных эксплуатационных данных и включает двухкритериальную процедуру валидации обновленной модели перед вводом в эксплуатацию.

Внедрение разработанного цикла взаимодействия оператора с системой поддержки принятия решений, включающего последовательные этапы от приема телеметрии до накопления обратной связи для переобучения модели, позволило выстроить замкнутый контур непрерывного улучшения. Число незапланированных остановок оборудования сократилось в 4 раза.

Результаты диссертационного исследования С.В. Горевы позволяют оптимизировать процесс принятия решений при эксплуатации оборудования и сокращать непроизводительные простои.

Генеральный директор
АО «Инвест Альянс»

А.А. Цемка

153021, Россия, г. Иваново,
ул. Кузнецова, 116
www.ivchimprom.com



тел/факс (4932) 57-00-98
тел. (4932) 57-00-99
e-mail: office@ivchimprom.ru

КОДЫ: ИНН 3731001968, КПП 370201001, ОКПО 05744685, ОКОНХ 13170, ОКАТО 24401370000, ОКТМО 24701000
БАНКОВСКИЕ РЕКВИЗИТЫ АО «ИВХИМПРОМ»: Р/счет: 40702810317000100268 Тульское отделение № 8604
ПАО Сбербанк, БИК 047003608, Кор/счет: 30101810300000000608

№ 1-Д/9-48
от « 13 » 04 2026 г.

В Диссертационный Совет

АКТ

об апробации результатов диссертационного исследования
Горева Сергея Владимировича

В рамках научно-технического сотрудничества между АО «ИВХИМПРОМ» и ФГБОУ ВО «Ивановский государственный химико-технологический университет» проведена опытно-промышленная апробация методики формирования признакового пространства, разработанной в диссертационном исследовании С.В. Горева «Модели и алгоритмы интеллектуального управления многослойной криогенной системой». Апробация выполнена на задаче автоматизированного мониторинга состояния теплообменного оборудования в условиях дисбаланса классов и ограниченных вычислительных ресурсов локального контроллера.

Применен разработанный автором алгоритм формирования признакового пространства, включающий конструирование производных признаков на основе физических соотношений между параметрами контролируемых сред, количественную валидацию вклада признаков методом аддитивной декомпозиции решений и представление результатов классификации с визуализацией факторов, определивших рекомендацию. Суммарный вклад сконструированных производных признаков составил более 70 %, что подтверждает физическую обоснованность выбранных конструкций.

Сформированная модель удовлетворила ограничениям локального контроллера по объему памяти и времени формирования прогноза. Результаты подтверждают переносимость методики на смежные классы задач обработки сенсорной информации в системах автоматизации производственных процессов.

Результаты диссертационного исследования С.В. Горева представляют научный и практический интерес и могут быть использованы при разработке систем автоматизированного мониторинга технологического оборудования.

С уважением,

ВРИО генерального директора



С.Н. Хахин

Система Менеджмента предприятия отвечает

требованиям международного стандарта ISO 9001

CERTIFIED
ISO 9001



Министерство науки и высшего образования
Российской Федерации

Федеральное государственное бюджетное
образовательное учреждение
высшего образования

**«ИВАНОВСКИЙ ГОСУДАРСТВЕННЫЙ
ХИМИКО-ТЕХНОЛОГИЧЕСКИЙ
УНИВЕРСИТЕТ»
(«ИГХТУ»)**

пр. Шереметевский, д. 7, Иваново, 153000
тел. (4932) 32-92-41, факс (4932) 41-79-95
E-mail: rector@isuct.ru, http://www.isuct.ru

ИНН/КПП 3728012818 / 370201001

19.04.2026 № 01-11/95

на № _____ от _____

В Диссертационный Совет 24.2.281.04
при ВлГУ имени А.Г. и Н.Г. Столетовых

АКТ

о внедрении результатов диссертационного исследования
Горева Сергея Владимировича в учебный процесс ИГХТУ

Результаты диссертационного исследования Горева Сергея Владимировича на тему «Модели и алгоритмы интеллектуального управления многослойной криогенной системой», выполненного на кафедре «Информационные технологии и цифровая экономика» ИГХТУ, используются в учебном процессе Ивановского государственного химико-технологического университета.

Разработанные автором методы и подходы внедрены в образовательный процесс. Они используются в качестве учебно-методических материалов и при проведении лабораторных работ по следующим дисциплинам: «Технология обработки информации», «Теория информации, данные, знания» и «Информационные технологии» (программа бакалавриата по направлению 09.03.02 «Информационные системы и технологии»). В университете на практике реализуются разработанные автором алгоритм формирования признакового пространства и конвейер предобработки телеметрических данных. Указанные алгоритмы применяются в качестве примеров при изучении методов предобработки и конструирования признаков, а также при выполнении лабораторных работ по классификации данных в условиях дисбаланса классов и ограниченных вычислительных ресурсов. Кроме того, при изучении способов формализации прикладных задач обработки информации используются предложенные автором решения по классификации состояний технической системы как вариант многокритериальной оптимизации с ограничениями на вычислительные ресурсы встраиваемого контроллера.

По дисциплине «Модели информационных процессов и систем» (программа магистратуры по направлению 09.04.02 «Информационные системы и технологии») используется разработанная автором функциональная модель системы поддержки принятия решений, формализующая полный цикл обработки информации от сбора данных до формирования управленческого решения оператором, а также модель адаптации на эксплуатационных данных с двухкритериальной валидацией. Материалы диссертации применяются при изучении методов моделирования информационных процессов в системах управления техническими объектами и построения систем поддержки принятия решений с механизмом обратной связи.

Реализация результатов диссертационного исследования С.В. Горева в учебном процессе способствует повышению качества подготовки обучающихся Ивановского государственного химико-технологического университета и формированию профессиональных компетенций в области обработки информации и интеллектуального управления техническими системами.

Ректор

Гордина Н.Е.

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2025614055

**Программа интеллектуальной поддержки принятия
решений для управления многослойной криогенной
системой с использованием методов машинного
обучения**

Правообладатель: *Федеральное государственное бюджетное
образовательное учреждение высшего образования
«Ивановский государственный химико-технологический
университет» (RU)*

Авторы: *Горев Сергей Владимирович (RU), Астраханцева Ирина
Александровна (RU)*



Заявка № 2025612232

Дата поступления 07 февраля 2025 г.

Дата государственной регистрации

в Реестре программ для ЭВМ 18 февраля 2025 г.

Руководитель Федеральной службы
по интеллектуальной собственности

документ подписан электронной подписью
Сертификат: 0692e70a0b300c154f24016700cc2020
Владельцу: **Зубов Юлий Сергеевич**
Действителен с 18.02.2024 по 03.10.2025

Ю.С. Зубов

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2025684788

Программа для сбора и обработки данных многослойной криогенной системой

Правообладатель: *Горев Сергей Владимирович (RU)*

Автор(ы): *Горев Сергей Владимирович (RU)*



Заявка № 2025683896

Дата поступления **20 августа 2025 г.**

Дата государственной регистрации

в Реестре программ для ЭВМ **17 сентября 2025 г.**

Руководитель Федеральной службы
по интеллектуальной собственности

документ подписан и скреплен подписью
Сертификат D:\S\Toshiba\040670.docx 2025
Владимир Зубов Юрий Сергеевич
Действителен с 10.09.2024 по 03.08.2025

Ю.С. Зыдов