



МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ РОССИЙСКОЙ ФЕДЕРАЦИИ  
федеральное государственное бюджетное образовательное учреждение  
высшего образования  
«РОССИЙСКИЙ ГОСУДАРСТВЕННЫЙ  
ГИДРОМЕТЕОРОЛОГИЧЕСКИЙ УНИВЕРСИТЕТ»

Кафедра Информационных технологий и систем безопасности

**ВЫПУСКНАЯ КВАЛИФИКАЦИОННАЯ РАБОТА**  
(Бакалавр)

На тему Разработка модели аппаратного обеспечения системы автономного управления подводным подвижным аппаратом

Исполнитель Оханов Роман Андреевич  
(фамилия, имя, отчество)

Руководитель д.т.н., доцент  
(ученая степень, ученое звание)

Бурлов Вячеслав Георгиевич  
(фамилия, имя, отчество)

«К защите допускаю»

Заведующий кафедрой

\_\_\_\_\_  
(подпись)

\_\_\_\_\_  
доктор технических наук  
(ученая степень, ученое звание)

\_\_\_\_\_  
Бурлов Вячеслав Георгиевич  
(фамилия, имя, отчество)

« \_\_\_ » \_\_\_\_\_ 2023 г.

Санкт–Петербург  
2023

## СОДЕРЖАНИЕ

|  |    |
|--|----|
| Введение .....   | 6  |
| Глава 1. Оценка состояния бортовых систем .....  | 10 |
| 1.1 Виды и классификация бортовых систем .....   | 10 |
| 1.2 Оценка состояния процессов узлов и устройств бортовых систем .....                                   | 16 |
| 1.3 Постановка задачи.....   | 21 |
| Глава 2. Адаптивное применение моделей машинного обучения для оценки состояния бортовых систем .....     | 25 |
| 2.1 Применение методов машинного обучения для оценки состояния бортовых систем.....                      | 26 |
| 2.2 Повышение качества оценки состояния бортовых систем за счет сегментирования выборки данных.....      | 43 |
| 2.3 Преимущества и ограничения существующих подходов (выделить достоинства и недостатки методов МО ..... | 47 |
| Глава 3. Адаптивное применение моделей машинного обучения при оценке состояния ИБ бортовых систем .....  | 55 |
| 3.1 Формирование сегментов выборки данных и их обработка методами МО .....                               | 55 |
| 3.2 Экспериментальная оценка предложенного подхода .....   | 59 |
| Заключение .....   | 68 |
| Список используемой литературы .....   | 71 |

## ВВЕДЕНИЕ

В современном мире разработка и применение автоматизированных систем управления в различных сферах деятельности становится все более актуальной задачей. В частности, в морской отрасли возникает потребность в создании средств мониторинга состояния бортовых систем судна, позволяющих выявлять сбои в процессе функционирования объектов морской техники, фиксировать возможные злонамеренные воздействия на систему. Это необходимо для обеспечения безопасности судоходства, предотвращения аварийных ситуаций, выявления инцидентов, связанных с нарушением информационной безопасности. В связи с лавинообразным ростом количества обрабатываемой морскими информационными системами данных, решение задач классификации и прогнозирования состояний объектов морской техники связано с необходимостью решения ряда проблемных вопросов обработки многомерных информационных потоков. Это обусловлено тем, что устройства бортовых систем подвержены внешним и внутренним воздействиям, вызывающим быстрые переходы из одного состояния в другое. Распределение анализируемых данных может изменяться с течением времени. Возникает необходимость в создании методов адаптивного обучения и использования моделей, позволяющих идентифицировать состояние бортовых систем в динамически меняющихся и нестационарных средах.

Для обработки множества данных возможно применение различных моделей и методов машинного обучения, которые позволят оценить состояние морской информационной системы и предсказать возможные сбои в их работе. Увеличение количества источников информации о протекающих процессах в определенных случаях позволяет повысить качественные показатели обрабатываемой информации. Кроме того, возможно вычисление дополнительных статистических характеристик временных последовательностей и потоков, которые позволяют в явном или неявном виде учитывать различные воздействующие факторы. Выявление границ и точек «разладки» для временных рядов дают возможность осуществить анализ не всей

выборки, а ее отдельных частей. Определив свойства сегментов и обучив на них алгоритм, возможно осуществить выбор наиболее подходящих моделей для каждого сегмента с их последующим объединением.

Таким образом, адаптивное применения моделей машинного обучения на отдельных сегментах выборки данных для оценки состояния бортовых систем, направленных на разрешение противоречий между возрастающими потребностями повышения показателей безопасности и надежности функционирования объектов морской техники и традиционными способами анализа состояния бортовых систем, является актуальной научной проблемой.

Целью выпускной квалификационной работы является изменение и адаптации существующих моделей интеллектуального анализа данных, и разработка нового алгоритма, позволяющего производить адаптивное обучение. Необходимо осуществлять автоматическую обработку выборок данных для определения свойств отдельных сегментов и назначения наиболее подходящих классификационных моделей.

Объектом исследования являются устройства и элементы бортовых автоматизированных систем.

Предметом исследования являются модели машинного обучения и возможность их адаптивного применения на отдельных сегментах выборки данных[1,2].

Для достижения поставленной в рамках выпускной квалификационной работы цели были решены следующие частные научно-технические задачи:

1. Проведен анализ возможности функционирования бортовых систем;
2. Обоснованы требования по надежности и безопасности функционирования этих систем;
3. Произведен обзор методов анализа работоспособности в ходе функционирования устройств и узлов бортовых систем;
4. Изучены существующие методы и модели машинного обучения, используемые для анализа и прогнозирования состояния бортовых систем судна;

5. Разработан метод адаптивного применения моделей машинного обучения на отдельных сегментах выборки для оценки состояния бортовых систем судна.

6. Применены математические модели (модели методов машинного обучения) для разработки метода адаптивного применения моделей машинного обучения на отдельных сегментах выборки;

7. Произведена оценка эффективности предложенного решения.

Для решения поставленных задач в выпускной квалификационной работе использовались методы математического, теории вероятностей и математической статистики, теории классификации, теории графов, теории защиты информации, теории надежности, методы машинного обучения.

Для анализа и обработки данных были использованы современные программные пакеты и библиотеки машинного обучения, такие как Python, TensorFlow, Keras, Pandas и другие.

Научная новизна работы заключается в разработке метода адаптивного применения моделей машинного обучения на отдельных сегментах выборки для оценки состояния бортовых систем судна. Данный метод позволяет улучшить точность и эффективность оценки состояния бортовых систем за счет более точного определения параметров систем и прогнозирования их состояния на основе адаптивной выборки.

Выпускная квалификационная работа состоит из введения, трех глав, заключения и списка использованной литературы. Содержание первой главы полностью посвящено теоретической части по теме объекта исследования. Во второй главе рассматривается предлагаемый метод решения поставленной проблемы. В третьей главе приводится, описание экспериментальной части и оценка применимости разработанного метода.

В процессе написания данной работы использовались научные и учебно-методические работы отечественных и зарубежных авторов, публикации в научных журналах и материалы периодической печати.

Практическая значимость работы заключается в возможности использования разработанного метода для создания дополнительных систем мониторинга состояния бортовых автоматизированных систем. Результаты исследования могут быть использованы морскими компаниями и судостроительными предприятиями для повышения надежности и безопасности судов.

Таким образом, предложенный подход имеет потенциал для применения в морской отрасли и может внести значительный вклад в область разработки морских информационных систем.

# ГЛАВА 1. МЕТОДИКА АНАЛИЗА ИНФОРМАЦИОННОЙ БЕЗОПАСНОСТИ БОРТОВЫХ ПЕРСОНАЛЬНЫХ СЕТЕЙ

Глава 1 «Оценка состояния бортовых систем» посвящена изучению процессов оценки состояния бортовых систем на судне. В рамках данной главы будут рассмотрены виды и классификации бортовых систем, а также методы оценки их состояния. В результате анализа предметной области в рамках объекта исследования осуществляется постановка научной задачи.

## 1.1 Виды и классификация бортовых систем

### Навигационные системы

Навигационные системы являются одними из наиболее важных бортовых систем на судне, которые обеспечивают надежное определение местоположения и ориентацию судна в морском пространстве. Существует множество различных типов навигационных систем, включая системы глобальной навигации (GPS, GLONASS, Galileo), системы локальной навигации (ЛПСН), системы радионавигации (ДМБН, РЭБ), системы инерциальной навигации (ИНС) и многие другие.

Каждая из этих систем имеет свои особенности и применяется в различных условиях и задачах на судне. Например, системы глобальной навигации позволяют определять местоположение судна с высокой точностью в любых точках земного шара, а системы инерциальной навигации обеспечивают высокую точность определения местоположения и ориентации судна даже при отсутствии внешних ориентиров.

Оценка состояния навигационных систем на судне является важной задачей для обеспечения безопасной навигации и предотвращения возможных аварийных ситуаций. Различные методы машинного обучения могут быть использованы для анализа и оценки состояния навигационных систем, что позволяет своевременно выявлять возможные проблемы и сбои в работе этих систем и принимать меры по их устранению.

## Электронные системы

Электронные системы широко используются на современных судах для управления и контроля различных систем и процессов. Они могут быть разделены на несколько категорий в зависимости от функций, которые они выполняют[2,4].

Существует множество различных электронных систем, используемых на кораблях. К ним относятся:

- системы автоматического управления кораблем;
- системы дистанционного зондирования и контроля параметров окружающей среды;
- системы бортового электропитания;
- системы автоматического контроля и диагностики технического состояния оборудования;
- системы связи и навигации;
- системы контроля и управления радиационной обстановкой;
- системы управления балластом и т.д.

Каждая из этих систем выполняет свои специфические функции, но все они имеют общую цель - обеспечение безопасности и эффективности работы корабля. В связи с этим, разработка и совершенствование электронных систем является актуальной задачей для судостроительной отрасли.

Одной из самых важных категорий электронных систем являются системы автоматического управления судном. Они позволяют контролировать движение судна, управлять его курсом и скоростью, а также обеспечивать безопасность при маневрировании. Системы автоматического управления судном могут быть основаны на различных принципах, таких как гироскопический или акустический.

Еще одной важной категорией электронных систем на судне являются системы управления энергетическими ресурсами. Они могут включать в себя контроль генераторов, батарей и других источников энергии, а также системы

автоматического переключения между источниками энергии в зависимости от текущей нагрузки.

Также электронные системы на судне могут включать в себя системы навигации и обнаружения объектов в окружающей среде, такие как радары, эхолоты и системы определения местоположения. Эти системы необходимы для обеспечения безопасности судна и его экипажа, а также для выполнения различных задач, таких как поиск рыболовных мест или избежание столкновений с другими судами.

Кроме того, на судне могут быть установлены электронные системы контроля и управления механическим оборудованием, такие как системы автоматического управления двигателями, системы контроля топливного расхода и системы диагностики и ремонта.

Изучение и анализ работы электронных систем на судне позволяет определить их эффективность, выявить возможные проблемы и недостатки, а также разработать рекомендации по улучшению их работы.

#### Автоматизированные системы управления

Автоматизированные системы управления (АСУ) представляют собой комплекс технических средств и программных компонентов, предназначенных для автоматизации управления процессами в различных сферах, включая морскую промышленность. Они используются для контроля и управления различными системами судна, такими как система управления двигателями, система контроля и управления электрооборудованием, система управления грузоподъемностью, система управления расходом топлива, система управления скоростью и направлением движения, система контроля загрузки, система навигации и другими.

Одним из главных преимуществ использования АСУ в морской промышленности является повышение эффективности и надежности управления процессами на судне. Автоматизированные системы управления позволяют сократить число ошибок, связанных с человеческим фактором, повысить

скорость принятия решений и уменьшить время реакции на непредвиденные ситуации.

Существует несколько видов АСУ, в зависимости от сферы применения и уровня автоматизации процессов. Например, на малых судах могут использоваться относительно простые системы автоматизации, такие как системы автоматического управления движением, системы автоматического управления промышленными процессами и т.д. На больших судах, включая танкеры, контейнеровозы и другие, применяются более сложные системы автоматизации, включающие в себя датчики, контроллеры, программное обеспечение и другие компоненты.

Важным аспектом разработки и применения АСУ является обеспечение их надежности и безопасности. Для этого применяются различные методы и стандарты, включая стандарты по ИБ и надежности, а также методы анализа рисков.

В дальнейшем в рамках данной работы будет рассмотрен подход к оценке состояния автоматизированных систем управления на судне при помощи моделей машинного обучения, что позволит улучшить надежность и эффективность их работы.

#### Системы безопасности и защиты

Системы безопасности и защиты являются неотъемлемой частью бортовых систем современных транспортных средств. Они предназначены для обеспечения безопасности перевозимых людей и грузов, а также защиты транспортных средств от угроз внешней и внутренней среды.

Системы безопасности и защиты могут включать в себя различные устройства и компоненты, такие как:

- Системы контроля и управления движением транспортного средства, включая автоматические тормозные системы, системы управления ускорением и т.д.

- Системы контроля за внутренней и внешней средой транспортного средства, включая системы контроля за температурой, освещением, качеством воздуха и т.д.
- Системы обнаружения и предотвращения возгораний и аварийных ситуаций, включая системы пожарной безопасности, системы контроля за давлением в шинах и т.д.
- Системы обеспечения личной безопасности пассажиров, включая подушки безопасности, ремни безопасности, системы автоматического оповещения о происшествиях и т.д.

В зависимости от типа транспортного средства и условий эксплуатации, могут использоваться различные системы безопасности и защиты. Например, для морских судов могут использоваться системы автоматической пожарной защиты, системы спасательных шлюпок и т.д., в то время как для автомобилей - системы контроля за давлением в шинах, системы стабилизации и т.д.

Оценка состояния систем безопасности и защиты транспортных средств является важной задачей, поскольку от их исправной работы зависит безопасность перевозимых людей и грузов. В рамках данной работы будут рассмотрены различные методы и подходы к оценке состояния систем безопасности и защиты на примере бортовых систем различных видов транспорта.

#### Энергетические системы

Энергетические системы включают в себя комплекс оборудования, необходимый для обеспечения энергией всех систем и устройств судна. Они играют важную роль в обеспечении энергетической безопасности судна, а также в работе его бортовых систем.

Современные энергетические системы на судах могут использовать различные источники энергии, такие как дизельные генераторы, газовые турбины, солнечные батареи, ветрогенераторы и др. Кроме того, могут быть

установлены системы энергосбережения, например, системы рекуперации тепла и системы регулирования мощности генераторов.

Оценка состояния энергетических систем является важным элементом обеспечения надежной и безопасной работы судна. Для этого используются различные методы и средства мониторинга и контроля, такие как системы автоматического контроля энергопотребления, датчики параметров работы генераторов и турбин, системы контроля уровня топлива и масла, системы контроля температуры и давления в системах охлаждения и т.д.

Целью оценки состояния энергетических систем является обеспечение их надежной и безопасной работы во время эксплуатации судна. Это позволяет предотвратить возможные аварии, связанные с неисправностью энергетических систем, а также оптимизировать энергопотребление и снизить затраты на топливо.

#### Системы связи и информационные системы

Системы связи и информационные системы играют важную роль в современных бортовых системах и обеспечивают передачу данных и команд между различными устройствами. Они включают в себя различные компоненты, такие как радиолокационное оборудование, радиосвязь, системы спутниковой связи и другие.

Радиолокационное оборудование используется для обнаружения и отслеживания объектов, а также для определения расстояний и направлений. Радиосвязь обеспечивает передачу голосовых и текстовых сообщений между различными членами экипажа, а также между кораблем и внешним миром. Системы спутниковой связи используются для передачи данных и команд на большие расстояния и в условиях отсутствия наземной связи.

Также важным компонентом являются информационные системы, которые обеспечивают сбор, обработку и передачу различных данных на борту корабля. Они могут включать в себя системы автоматической и ручной

обработки данных, системы навигации и позиционирования, а также системы мониторинга и контроля за различными параметрами корабля.

Подобные системы могут быть использованы для управления бортовыми системами, обеспечения безопасности и защиты корабля, а также для сбора и передачи различных данных, необходимых для принятия решений экипажем.

## 1.2 Оценка состояния процессов узлов и устройств бортовых систем

### Оценка состояния узлов и устройств бортовых систем

- Понятие "состояние узлов и устройств бортовых систем"

Понятие "состояние узлов и устройств бортовых систем" включает в себя описание текущего функционального состояния, технического состояния и состояния надежности. Функциональное состояние определяет готовность узла или устройства к выполнению своих функций. Техническое состояние определяет фактическое состояние узла или устройства в соответствии с его проектной документацией. Состояние надежности определяет вероятность безотказной работы узла или устройства в течение определенного периода времени при определенных условиях эксплуатации. В общем случае, состояние узла или устройства может быть определено путем анализа информации, полученной от датчиков и других источников, которые непосредственно или косвенно связаны с этими узлами или устройствами. Оценка состояния является важной задачей для обеспечения безопасности и надежности эксплуатации бортовых систем[5].

- Классификация состояний узлов и устройств бортовых систем

Классификация состояний узлов и устройств бортовых систем представляет собой важную задачу в области оценки состояния бортовых систем. Для решения этой задачи были разработаны различные подходы и методики.

Одним из основных подходов является классификация состояний узлов и устройств на основе ГОСТов по ИБ (информационной безопасности) и

надежности. В соответствии с этими ГОСТами, состояния узлов и устройств могут быть классифицированы на следующие категории:

1. Работоспособное состояние - узел или устройство функционирует в нормальном режиме без отклонений от заданных параметров.
2. Состояние предотказа - узел или устройство находится на грани отказа, но еще функционирует и выполняет свои функции.
3. Отказавшее состояние - узел или устройство перестало функционировать и не выполняет своих функций.
4. Резервное состояние - узел или устройство работает в резервном режиме, после отказа основного устройства.
5. Состояние технического обслуживания - узел или устройство находится в состоянии технического обслуживания или ремонта.
6. Состояние настройки - узел или устройство находится в состоянии настройки, калибровки или конфигурирования.

В зависимости от конкретной бортовой системы и ее устройств, список состояний может быть дополнен или изменен. Однако, вышеперечисленные категории состояний являются общепринятыми и широко используются в оценке состояния бортовых систем.

- Способы оценки состояния узлов и устройств бортовых систем

Оценка состояния узлов и устройств бортовых систем является важным аспектом их эксплуатации. Существует несколько способов оценки состояния бортовых систем, которые могут быть использованы в зависимости от конкретных задач и целей[6]:

1. Визуальный контроль: этот метод включает в себя визуальный осмотр узлов и устройств бортовых систем с целью обнаружения явных признаков повреждений, износа или неисправности. Этот метод может быть полезен при первичном осмотре системы, однако он может быть недостаточным для выявления скрытых дефектов.

2. Испытания: этот метод включает проведение различных испытаний узлов и устройств бортовых систем, таких как тесты на прочность, испытания на износ, термические испытания и т.д. Этот метод может помочь выявить скрытые дефекты и недостатки, однако он может быть трудоемким и затратным.

3. Мониторинг: этот метод включает установку датчиков и сенсоров на узлы и устройства бортовых систем для непрерывного мониторинга их состояния. Это позволяет оперативно выявлять любые изменения в состоянии системы и принимать меры по их устранению. Этот метод может быть особенно полезен для систем, работающих в условиях высокой нагрузки и частых перегрузок.

4. Диагностика: этот метод включает использование специального оборудования и программного обеспечения для диагностики узлов и устройств бортовых систем. Диагностика может проводиться как в статическом, так и в динамическом режиме, что позволяет выявлять широкий спектр дефектов и неисправностей. Этот метод может быть особенно полезен для сложных систем, где визуальный контроль и испытания недостаточны.

Каждый из этих методов может быть эффективен в зависимости от конкретной задачи и условий эксплуатации бортовых систем. Однако наиболее эффективным подходом может быть комплексное использование всех

#### ГОСТы по ИБ и надежности бортовых систем

##### ➤ Понятие "ГОСТ"

Понятие "ГОСТ" обозначает государственный стандарт, утвержденный органами государственного управления Российской Федерации и других государственных органов. ГОСТ устанавливает требования к продукции, процессам и услугам, а также методы испытаний и измерений, которые необходимо соблюдать в определенной области. Данный стандарт является обязательным для применения в России, а также может использоваться в других странах в качестве рекомендательных

документов. В области оценки состояния бортовых систем применяются различные ГОСТы по надежности, безопасности и качеству, которые устанавливают необходимые требования для обеспечения надежной и безопасной работы технических средств.

➤ ГОСТы по ИБ бортовых систем

Существует множество ГОСТов по ИБ, которые регулируют процессы и требования, связанные с защитой информации на борту транспортных средств. Они определяют правила и методы обеспечения безопасности информации, передаваемой и обрабатываемой в системах связи и информационных системах.

Некоторые из наиболее распространенных ГОСТов по ИБ, которые могут использоваться при оценке состояния бортовых систем, включают в себя:

- ГОСТ Р ИСО/МЭК 27001:2013 "Информационная технология. Методы обеспечения информационной безопасности. Системы менеджмента информационной безопасности. Требования";
- ГОСТ Р 53768-2010 "Информационная технология. Защита информации. Методы и средства защиты";
- ГОСТ Р ИСО/МЭК 15408-2016 "Информационная технология. Оценка соответствия требованиям безопасности. Части 1-3".

Каждый из этих ГОСТов содержит рекомендации и правила, которые могут быть применены для оценки состояния системы ИБ бортовых систем. Оценка соответствия бортовых систем ГОСТам по ИБ может помочь определить уязвимости в системе и сделать рекомендации по повышению безопасности передаваемой и обрабатываемой информации.

➤ ГОСТы по надежности бортовых систем

ГОСТы по надежности бортовых систем - это стандарты и требования, установленные в Российской Федерации для обеспечения высокой надежности функционирования бортовых систем различного

назначения. Они определяют методы, правила и процедуры для обеспечения безопасной эксплуатации бортовых систем, а также устанавливают критерии для оценки и контроля качества работы систем.

ГОСТы по надежности бортовых систем включают в себя ряд стандартов, регулирующих различные аспекты функционирования систем, такие как:

- требования к надежности системы в целом;
- требования к надежности отдельных узлов и устройств системы;
- требования к процессу сборки, монтажа и наладки системы;
- требования к эксплуатации и техническому обслуживанию системы.

Примеры таких ГОСТов:

- ГОСТ Р ИСО 26262 "Функциональная безопасность систем автоматического управления автомобилями"
- ГОСТ Р 52853 "Системы транспортные автоматические. Требования к надежности и качеству обслуживания"
- ГОСТ Р 52934 "Бортовые радиотехнические средства. Требования к надежности и качеству обслуживания"
- ГОСТ Р 55088 "Бортовые технические средства. Требования к надежности и качеству обслуживания"

Соблюдение ГОСТов по надежности является важным условием обеспечения безопасности эксплуатации бортовых систем и предотвращения возможных аварийных ситуаций.

#### ➤ Примеры ГОСТов, применяемых в бортовых системах

Существует множество ГОСТов, применяемых в бортовых системах для обеспечения их безопасности и надежности. Некоторые из них перечислены ниже:

1. ГОСТ Р 53245-2009 "Системы обнаружения и пожаротушения воздушных судов" - этот ГОСТ регулирует требования к системам обнаружения и пожаротушения на борту воздушных судов.

2. ГОСТ Р 52122-2003 "Аварийно-спасательное обеспечение" - этот ГОСТ устанавливает требования к аварийно-спасательному обеспечению на борту воздушных судов.

3. ГОСТ Р 54111–2010 "Системы автоматического управления полетом" - этот ГОСТ регулирует требования к системам автоматического управления полетом на борту воздушных судов.

4. ГОСТ Р 54617-2011 "Системы навигации и управления полетом" - этот ГОСТ устанавливает требования к системам навигации и управления полетом на борту воздушных судов.

5. ГОСТ Р 55148-2012 "Системы электропитания бортовых комплексов летательных аппаратов" - этот ГОСТ регулирует требования к системам электропитания бортовых комплексов на борту летательных аппаратов.

6. ГОСТ Р 55957-2014 "Системы связи и передачи данных на борту воздушных судов" - этот ГОСТ устанавливает требования к системам связи и передачи данных на борту воздушных судов.

7. ГОСТ Р 56092-2014 "Системы обработки и управления информацией на борту воздушных судов" - этот ГОСТ регулирует требования к системам обработки и управления информацией на борту воздушных судов.

### 1.3 Постановка задачи

- **Общая постановка задачи**

На сегодняшний день не существует универсальных алгоритмов, позволяющих достичь заданного качества обработки данных с различными свойствами. Определение оптимального алгоритма обучения для конкретной выборки является трудоемким, многоитерационным процессом. В связи с этим возникает необходимость реализации модели, объединяющей несколько алгоритмов, для улучшения качественных показателей принятых решений.

Особенности алгоритмов классификации, свойств информации оказывают влияние на эффективность применения различных классификаторов. В

зависимости от требуемых показателей полноты, точности, скорости обработки выбираются алгоритмы, обладающие своими уникальными характеристиками. Для достижения требуемых показателей приходится проводить ряд процедур, направленных на настройку, обработку данных, связанных с удалением выбросов и шумов.

Уточнение локальной информации является одним из подходов к разработке, адаптации и использованию моделей, направленных на повышение качественных показателей процесса классификации состояния [7,8].

Анализ обучающей выборки предполагает ее обработку как единой последовательности. Однако возможна сегментация данных на подмножества в момент воздействия различных внешних и внутренних факторов. Например, рост интенсивности появления служебных сообщений в сетях происходит из-за появления ряда управляющих команд. Некоторые факторы либо известны заранее, либо поддаются прогнозированию, что дает возможность учесть их воздействие на значения переменных. В связи с этим возможно произвести разделение выборки на подмножества и определить кортежи, полученные в момент различных воздействий на ИТКС.

Рассмотрим  $X^q$  – выборку размером  $q$ .  $\{a_1, a_2, \dots, a_r\} \in A$  – множество классифицирующих алгоритмов,  $a(x)$  – результирующая модель, решающая задачу классификации. В момент формирования выборки воздействует множество известных факторов  $\{v_1, v_2, \dots, v_m\} \in V$ , влияющих на значения целевых переменных в кортежах  $x \in X^q$ . Для оценки качества классифицирующих алгоритмов  $a_1, a_2, \dots, a_r$  используется функция потерь  $L$ , рассчитываемая как разница между фактическим выходным значением и прогнозируемым выходным значением. Определим  $L(a, x, v)$  как функцию потерь в момент действия фактора  $v$ . Тогда с учетом  $v$  средняя величина ошибки определяется выражением:

$$Q(a, X^q, v) = \frac{1}{q} \sum_{x \in X} L(a, x, v). \quad (1)$$

Необходимо минимизировать функционал качества по параметру  $a$ :

$$Q(a, X^q, v) \rightarrow \min. \quad (2)$$

Такая постановка позволяет учитывать эффекты, влияющие на разброс, смещение ответов классификаторов, образуемых воздействием известных факторов.

Для достижения общей цели - повышения надежности и безопасности функционирования бортовых систем, в данном исследовании ставятся следующие задачи:

1. Анализ существующих методов и подходов к оценке надежности и безопасности бортовых систем, включая анализ ГОСТов и стандартов, применяемых в данной области[9].
2. Оценка надежности и безопасности бортовых систем, учитывающей особенности их работы и эксплуатации.
3. Проведение экспериментального исследования надежности и безопасности выбранных бортовых систем на основе разработанного метода.
4. Анализ полученных результатов экспериментального исследования, определение причин возможных отклонений от ожидаемых значений.
5. Оценка применимости разработанного метода адаптивного метода для повышения надежности и безопасности бортовых систем.

Результаты данного исследования могут быть использованы для улучшения надежности и безопасности бортовых систем различных видов морского транспорта.

#### ▪ Методы исследования

Для оценки состояния узлов и устройств бортовых систем могут использоваться различные датчики и диагностические методы, такие как мониторинг параметров работы систем, анализ трендов, диагностические тесты, вибрационный анализ, термография и др.

Для анализа полученных данных могут применяться различные алгоритмы и методы, включая статистический анализ, машинное обучение, нейронные сети

и др. Также могут использоваться специальные программы и системы управления данными для обработки и хранения полученных результатов.

Эффективность оценки состояния узлов и устройств бортовых систем зависит от правильного выбора методов и инструментов, а также от правильной интерпретации полученных данных[10].

## Вывод

Глава 1 посвящена описанию бортовых систем, их составляющих, а также способов оценки их состояния. Рассмотрены различные типы бортовых систем, начиная от навигационных и электронных систем, и заканчивая системами безопасности и энергетическими системами.

В рамках главы было детально описано понятие "состояние узлов и устройств бортовых систем", их классификация и способы оценки. Также рассмотрены ГОСТы, посвященные оценке надежности и информационной безопасности.

Заключительные пункты главы были посвящены постановке задачи, целям и методам исследования. Была определена главная цель исследования - улучшение надежности и безопасности бортовых систем, а также описали подходы и методы, которые используются для достижения этой цели.

## ГЛАВА 2. АДАПТИВНОЕ ПРИМЕНЕНИЕ МОДЕЛЕЙ МАШИННОГО ОБУЧЕНИЯ

Во второй главе выпускной квалификационной работы рассматривается возможность применения моделей машинного обучения для оценки состояния бортовых систем. Машинное обучение является мощным инструментом, позволяющим извлекать информацию из данных и применять ее для прогнозирования и оценки различных параметров и состояний.

В разделе 2.1 мы исследуем применение методов машинного обучения в контексте оценки состояния бортовых систем. Мы рассмотрим различные методы машинного обучения и проведем их классификацию, чтобы понять их особенности и применимость. Особое внимание будет уделено областям применения этих методов, включая морские информационные системы, где оценка состояния бортовых систем имеет важное значение для надежного и безопасного функционирования[11,12].

В разделе 2.2 исследуется возможность повышения качества оценки состояния бортовых систем путем сегментации выборки данных. Сегментация данных позволяет адаптировать модели машинного обучения к различным сегментам системы и улучшить точность их прогнозов. Мы исследуем различные подходы к сегментации данных и их применимость в контексте оценки состояния бортовых систем, особенно в условиях переменных условий и неопределенностей.

В разделе 2.3 мы проведем анализ преимуществ и ограничений существующих подходов к применению моделей машинного обучения для оценки состояния бортовых систем. Мы выявим достоинства и недостатки данных подходов, учитывая такие факторы, как вычислительные затраты, доступность и объем данных, особенности и распределение данных, а также сложности при обработке и анализе больших объемов информации. Это позволит нам лучше понять, какие методы машинного обучения наиболее

эффективны в контексте оценки состояния бортовых систем и какие ограничения могут быть преодолены или учтены.

## 2.1 Применение методов машинного обучения для оценки состояния бортовых систем

Методы машинного обучения (ML) - это алгоритмы и модели, которые позволяют компьютерным системам учиться на основе данных и делать предсказания или принимать решения без явного программирования. ML используется для решения задач классификации, регрессии, кластеризации, обработки естественного языка и многих других. Он находит свое применение в различных областях, включая медицину, бизнес, финансы, транспорт и т.д.[13].

### Области применения методов машинного обучения

- Бортовые системы (авиация, судоходство, автомобильная промышленность и др.)

Методы машинного обучения нашли широкое применение в области бортовых систем, которые используются в авиации, судоходстве, автомобильной промышленности и других смежных отраслях. Эти системы отвечают за управление и мониторинг различных аспектов работы транспортных средств, обеспечивая безопасность, эффективность и комфорт пассажиров. Вот несколько областей, где методы машинного обучения применяются в бортовых системах:

1. Прогнозирование технического состояния различных систем и компонентов транспортных средств. На основе данных о прошлых поломках, измерениях и других параметрах модели машинного обучения могут предсказывать вероятность возникновения отказов или неисправностей в будущем. Это позволяет проводить проактивное техническое обслуживание,

устраняя проблемы до их возникновения, и повышать надежность и безопасность транспортных средств.

2. Распознавание образов и детекция объектов на основе данных, полученных с помощью датчиков и камер. Например, в авиации они могут использоваться для автоматического распознавания и классификации навигационных маркеров или для обнаружения и отслеживания других воздушных судов. В автомобильной промышленности методы машинного обучения применяются для систем помощи водителю, таких как распознавание знаков дорожного движения и предупреждение о возможных столкновениях.

3. Оптимизация управления различными аспектами бортовых систем, такими как управление двигателем, автопилот или системы поддержания стабильности. Модели машинного обучения могут обучаться на основе исторических данных и адаптироваться к изменяющимся условиям для достижения оптимальной производительности и эффективности [14].

4. Распознавание и обработка речи: Методы машинного обучения применяются для распознавания и обработки речи в бортовых системах, позволяя взаимодействовать с транспортным средством через голосовые команды. Это может быть полезно, например, для управления навигацией, мультимедийными системами или системами управления климатом.

5. Адаптивные системы безопасности: Методы машинного обучения применяются для анализа и прогнозирования потенциальных опасностей и рисков на дороге, в воздухе или на воде. На основе данных о движении, окружающей среде и поведении других объектов, адаптивные системы безопасности могут предупреждать водителя или автоматически принимать меры для предотвращения аварийных ситуаций.

6. Автоматическое управление и регулирование системами энергопотребления: Методы машинного обучения могут быть применены для

оптимизации энергопотребления в бортовых системах. На основе данных о нагрузке, энергетических потоках и других параметрах, модели машинного обучения могут анализировать и прогнозировать потребление энергии и эффективно распределять ресурсы для улучшения энергоэффективности и продолжительности работы транспортных средств.

7. Анализ и предсказание поведения пассажиров: Методы машинного обучения могут использоваться для анализа поведения пассажиров в транспортных средствах. На основе данных, собранных с различных датчиков, модели машинного обучения могут выявлять паттерны поведения пассажиров, определять их потребности и предлагать персонализированный сервис, улучшая комфорт и удовлетворенность клиентов.

8. Системы поддержки принятия решений: Методы машинного обучения могут помочь в разработке систем поддержки принятия решений для пилотов, капитанов судов и водителей. Модели машинного обучения могут анализировать данные о текущих условиях, прогнозах и исторических паттернах для предоставления рекомендаций и помощи в принятии решений в реальном времени.

9. Автоматическое распознавание и корректировка ошибок: Методы машинного обучения могут использоваться для автоматического распознавания и исправления ошибок в бортовых системах. Это может включать обнаружение и корректировку ошибок в навигационных данных, сенсорных данных или коммуникационных сетях, обеспечивая более надежную и точную работу систем.

10. Прогнозирование и оптимизация расходов: Методы машинного обучения могут быть использованы для прогнозирования и оптимизации расходов в транспортных средствах. На основе данных о стоимости топлива, дорожных условиях и других факторах, модели машинного обучения могут предсказывать оптимальные стратегии управления расходами, что приводит к снижению затрат и повышению экономической эффективности.

Методы машинного обучения в области бортовых систем значительно улучшают функциональность, безопасность и эффективность транспортных средств. Они способствуют автоматизации процессов, улучшению прогнозирования и принятию решений на основе данных, повышают уровень комфорта и безопасности для пассажиров и участников движения[15].

- Медицина и здравоохранение

Методы машинного обучения имеют широкий спектр применений в медицине и здравоохранении, где они играют важную роль в диагностике, лечении, прогнозировании и улучшении качества здравоохранения. Методы машинного обучения применяются для диагностики и обработки медицинских изображений (рентгенограммы, маммограммы, КТ-снимки и МРТ), прогнозирование заболеваний и результатов лечения (анализ данных пациентов, генетические данные, результаты лабораторных исследований и медицинские истории, для прогнозирования риска развития заболеваний и результатов лечения), анализ медицинских текстов (электронные медицинские записи, научные публикации и медицинские журналы), разработка протезов и систем реабилитации, управление медицинскими данными, оптимизации процессов здравоохранения и принятии решений на основе данных.

Методы машинного обучения в медицине и здравоохранении помогают улучшить точность диагностики, прогнозирование результатов лечения, оптимизацию процессов и принятие данных обоснованных решений. Они могут повысить эффективность и качество медицинской помощи, способствовать разработке новых методов лечения и улучшению здоровья и благополучия пациентов.

- Финансовый сектор

Методы машинного обучения имеют широкое применение в финансовом секторе, где они используются для различных задач, таких как прогнозирование финансовых рынков, анализ рисков, определение мошеннической активности и улучшение процессов принятия решений. Модели машинного обучения позволяют обрабатывать и анализировать большие объемы данных, выявлять скрытые закономерности и предсказывать будущие тренды и события. Это помогает финансовым учреждениям принимать более информированные решения, улучшать эффективность операций и минимизировать риски.

- **Промышленность и производство**

Методы машинного обучения играют важную роль в промышленности и производстве, где они применяются для оптимизации процессов производства, контроля качества, прогнозирования сбоев оборудования и управления ресурсами. Алгоритмы машинного обучения позволяют анализировать большие объемы данных, выявлять скрытые паттерны и зависимости, а также принимать автоматизированные решения на основе полученных результатов. Это способствует повышению эффективности производственных процессов, снижению затрат и повышению общей производительности. Машинное обучение также способствует развитию концепции "умных" производственных систем, где оборудование и процессы взаимодействуют и адаптируются на основе данных и аналитики для достижения оптимальных результатов.

- **Морские информационные системы (МИС)**

Методы машинного обучения также находят широкое применение в морских информационных системах (МИС), которые предоставляют

поддержку и управление в морских отраслях. Вот некоторые области применения методов машинного обучения в МИС:

1. Повышение безопасности судоходства и оптимизации навигационных процессов. Алгоритмы машинного обучения могут анализировать данные о состоянии морской среды, погодных условиях, движении судов, радарных и судовых датчиках, чтобы предсказывать потенциальные риски, предотвращать столкновения и предлагать оптимальные маршруты[16].

2. Обнаружение и идентификация объектов различных объектов в морской среде, таких как суда, плавучие препятствия, рыболовные сети и др. Алгоритмы машинного обучения могут анализировать данные с радаров, видеокамер, гидролокаторов и других датчиков для автоматического обнаружения и классификации объектов, что помогает улучшить морскую безопасность[17,18].

3. Прогнозирование морских условий, таких как волны, приливы, течения и погодные условия. Алгоритмы машинного обучения могут анализировать исторические данные, сенсорные измерения, данные о погоде и другие факторы для предсказания будущих изменений в морской среде. Это позволяет морским организациям принимать информированные решения и планировать действия, связанные с безопасностью и производственными операциями.

4. Мониторинг и управление морской экосистемой, включая океанские ресурсы, рыбные запасы и морскую биологическую разнообразность. Алгоритмы машинного обучения могут анализировать данные, полученные от датчиков, и обнаруживать паттерны, связанные с изменениями экосистемы, распространением вирусов или загрязнением морской среды. Это помогает принимать меры для сохранения морской жизни, рационального использования ресурсов и устойчивого развития морских отраслей[19].

5. Оптимизация морской логистики и управление поставками. Методы машинного обучения могут быть применены для оптимизации маршрутов доставки, управления складскими запасами и прогнозирования спроса на морские грузоперевозки. Алгоритмы машинного обучения анализируют исторические данные о грузах, расписаниях, портах и прочих факторах для предсказания оптимальных вариантов доставки, минимизации времени простоя судна и снижения издержек.

6. Автоматическое идентифицирование и отслеживание морских видов. Методы машинного обучения применяются для автоматического распознавания и классификации различных видов морской животной и растительной фауны. Алгоритмы анализируют данные, полученные с помощью подводных акустических и оптических датчиков, для обнаружения и отслеживания миграции, популяции и поведения морских видов, что помогает в охране природных ресурсов и биоразнообразия[20].

7. Прогнозирование и предотвращение аварий и стихийных бедствий. Методы машинного обучения применяются для анализа данных о морском трафике, метеорологических условиях и геологических параметрах с целью предсказания возможных аварийных ситуаций, таких как столкновения судов или близость к опасным географическим объектам. Это позволяет принимать меры предосторожности и своевременно предупреждать о потенциальных угрозах[21,22].

8. Оптимизация использования морских ресурсов и устойчивое рыболовство. Методы машинного обучения применяются для анализа данных о рыболовных уловах, экологических факторах и параметрах морской среды с целью оптимизации управления рыболовством. Алгоритмы машинного обучения могут помочь в прогнозировании наиболее благоприятных зон и периодов для рыболовных операций, установлении устойчивых квот на вылов и оценке состояния рыбных запасов.

9. Автоматизация процессов обнаружения и устранения морского загрязнения. Методы машинного обучения могут быть использованы для

обнаружения и классификации загрязнений в морской среде, таких как нефтяные пятна или пластиковые отходы. Алгоритмы анализируют данные с дронов, спутников и датчиков для идентификации и мониторинга участков загрязнения, что помогает в быстром реагировании и принятии мер для его устранения.

Морские информационные системы, поддерживаемые методами машинного обучения, играют важную роль в обеспечении безопасности, эффективности и устойчивости морских операций. Они помогают принимать информированные решения, оптимизировать процессы и снижать риски, связанные с морскими деятельностью.

Различные методы машинного обучения:

- Методы обучения с учителем

Методы обучения с учителем предоставляют широкий набор алгоритмов, которые позволяют оценивать состояние бортовых систем на основе размеченных данных. В этом подразделе мы рассмотрим три популярных метода обучения с учителем: линейную регрессию, деревья решений и случайный лес.

## 2. Линейная регрессия:

Линейная регрессия является простым и интерпретируемым методом, который моделирует линейную зависимость между входными признаками и целевой переменной. Она стремится найти оптимальные значения коэффициентов, которые минимизируют сумму квадратов разности между прогнозируемыми значениями и фактическими значениями целевой переменной. Линейная регрессия широко

используется для прогнозирования количественных переменных и может быть применена в оценке состояния бортовых систем для предсказания параметров, таких как эффективность, потребление энергии и т.д.

### 3. Деревья решений:

Деревья решений являются графическим представлением правил принятия решений. Каждый узел дерева представляет собой тест на определенный признак, а каждое ребро соответствует возможному значению этого признака. Дерево решений разделяет пространство признаков на различные регионы и позволяет классифицировать или предсказывать целевую переменную на основе значений признаков. Деревья решений могут быть использованы для оценки состояния бортовых систем путем классификации состояний или предсказания качественных переменных. Например, дерево решений может быть применено для определения состояния системы (нормальное, аварийное, предаварийное) на основе различных признаков, таких как температура, давление, скорость и другие.

### 4. Случайный лес:

Случайный лес представляет собой ансамбль деревьев решений. Он объединяет несколько деревьев решений и использует метод баггинга для получения итоговых прогнозов. Каждое дерево в случайном лесу строится на основе подвыборки данных с возвращением, а также случайного подмножества признаков. Это позволяет создавать разнообразные деревья, которые в совокупности образуют более точную модель. Случайный лес широко применяется в оценке состояния бортовых систем для предсказания параметров или классификации состояний. Он обладает хорошей устойчивостью к переобучению и способен обрабатывать большие объемы данных.

- Методы обучения без учителя

Методы обучения без учителя предоставляют инструменты для анализа неразмеченных данных и выявления скрытых закономерностей или структуры в данных. В этом подразделе мы рассмотрим два популярных метода обучения без учителя: кластеризацию и метод главных компонент (PCA).

1. Кластеризация:

Кластеризация является методом группировки объектов внутри набора данных на основе их сходства. Целью кластеризации является обнаружение скрытых групп или кластеров, где объекты внутри каждого кластера более похожи друг на друга, чем на объекты из других кластеров. Алгоритмы кластеризации могут определять число кластеров автоматически или требовать задания количества кластеров. Кластеризация может быть полезна при оценке состояния бортовых систем для выявления аномалий или группировки подобных состояний. Например, можно использовать кластеризацию для выделения групп схожих рабочих режимов или состояний системы, что поможет в дальнейшем анализе и принятии решений.

2. Метод главных компонент (PCA):

Метод главных компонент является статистическим методом, используемым для снижения размерности данных и извлечения наиболее значимых признаков. Он находит новые оси, называемые главными компонентами, которые являются линейными комбинациями исходных признаков и обладают свойством максимальной дисперсии. Главные компоненты упорядочены по убыванию вклада в объяснение общей дисперсии данных. Метод главных компонент позволяет сократить размерность данных и сжать информацию, сохраняя при этом наиболее важные характеристики данных. В контексте оценки состояния бортовых систем PCA может быть использован для сжатия данных с большим

числом признаков или для визуализации пространства признаков с помощью двух или трех главных компонент.

Эти методы обучения без учителя позволяют извлекать полезную информацию из данных без предварительного разметки и могут быть применены в задачах оценки состояния бортовых систем для обнаружения аномалий, группировки или сокращения размерности данных[23.24].

- Методы обучения с подкреплением

Методы обучения с подкреплением (reinforcement learning) отличаются от методов обучения с учителем и без учителя тем, что агент взаимодействует с окружающей средой, принимая последовательность действий, и получает положительные или отрицательные награды в зависимости от результатов своих действий. Целью обучения с подкреплением является нахождение оптимальной стратегии действий для агента, которая максимизирует накопленную награду на протяжении времени.

Одним из популярных методов обучения с подкреплением является Q-обучение (Q-learning). В Q-обучении агент стремится научиться оценивать ценность состояний и действий, используя функцию Q. Функция Q представляет собой оценку ожидаемой награды агента при выполнении определенного действия в конкретном состоянии. Агент обновляет значения функции Q на основе полученных наград и использует их для принятия решений о следующем действии.

Глубокое Q-обучение (deep Q-learning) представляет собой комбинацию метода Q-обучения с глубокими нейронными сетями. Вместо использования таблицы значений Q, глубокое Q-обучение использует нейронную сеть для аппроксимации функции Q. Это позволяет агенту

обрабатывать большие объемы данных и работать с непрерывным пространством состояний и действий. Глубокие нейронные сети в глубоком Q-обучении обучаются при помощи метода обратного распространения ошибки, который минимизирует разницу между оценками Q-значений, полученными от сети, и фактическими наградами агента.

Методы обучения с подкреплением, такие как Q-обучение и глубокое Q-обучение, могут быть полезными при оценке состояния бортовых систем, особенно при наличии динамического окружения и вариабельности входных данных. Они позволяют агенту изучать и приспосабливаться к изменяющимся условиям и выбирать оптимальные действия для достижения поставленных целей. Применение этих методов может помочь в анализе и определении состояния бортовых систем на основе их поведения и взаимодействия с окружающей средой.

Классификация методов машинного обучения для оценки состояния бортовых систем:

- Статистические методы (например, регрессия, временные ряды)

Статистические методы широко применяются в области оценки состояния бортовых систем для анализа данных, выявления зависимостей и построения прогностических моделей. Два распространенных статистических метода, используемых для оценки состояния, включают регрессию и анализ временных рядов.

Регрессия - это статистический метод, используемый для изучения взаимосвязи между зависимой переменной и одной или несколькими независимыми переменными. В контексте оценки состояния бортовых систем регрессия может использоваться для определения влияния различных

факторов на состояние системы. Например, можно построить регрессионную модель, чтобы оценить, какие параметры или показатели оказывают наибольшее влияние на работу системы, и использовать эту информацию для предсказания состояния в будущем. В качестве достоинств метода регрессии можно выделить его простоту и интерпретируемость, а также устойчивость к выбросам в данных и возможность выполнения интерполяции и экстраполяции. В качестве недостатков регрессии можно отметить предположение о функциональной форме связи и чувствительность к выбору предикторов.

Анализ временных рядов — это метод статистического моделирования и прогнозирования данных, упорядоченных во временной последовательности. В контексте оценки состояния бортовых систем, временные ряды могут представлять данные о работе системы, полученные с течением времени. Анализ временных рядов позволяет исследовать временные зависимости и тренды, а также выявлять сезонные колебания или аномалии в данных. Это может помочь в определении текущего состояния системы и прогнозировании ее поведения в будущем. В качестве достоинств метода анализа временных рядов можно выделить его способность к выявлению временных зависимостей и трендов, а также возможность обнаружения сезонных колебаний и аномалий в данных. В качестве недостатков анализа временных рядов можно отметить сложность интерпретации результатов и зависимость от качества и последовательности данных.

Статистические методы, такие как регрессия и анализ временных рядов, предоставляют структурированный и формализованный подход к оценке состояния бортовых систем. Они основаны на математических и статистических принципах, которые позволяют анализировать данные, выявлять закономерности и делать прогнозы. Эти методы могут быть полезны

для определения важных факторов, влияющих на состояние системы, и принятия решений на основе статистических выводов.

- **Нейронные сети и глубокое обучение**

Нейронные сети и глубокое обучение стали важными инструментами в области оценки состояния бортовых систем благодаря их способности автоматически извлекать сложные закономерности из больших объемов данных. Нейронные сети моделируют работу мозга, состоящего из множества взаимодействующих нейронов, и способны обрабатывать информацию на разных уровнях абстракции.

Глубокое обучение является разделом машинного обучения, в котором используются нейронные сети с несколькими слоями для изучения представлений данных. Вместо ручного определения признаков или характеристик, глубокое обучение позволяет модели самостоятельно извлекать признаки из данных на разных уровнях. Это позволяет обнаруживать более сложные зависимости и позволяет более точно оценивать состояние бортовых систем. В качестве достоинств метода нейронных сетей и глубокого обучения можно выделить их способность обрабатывать сложные и нелинейные зависимости в данных, высокую гибкость и адаптивность к различным задачам и возможность автоматического извлечения признаков. В качестве недостатков нейронных сетей и глубокого обучения можно отметить высокую вычислительную сложность, необходимость больших объемов данных для обучения и сложность интерпретации результатов.

Применение нейронных сетей и глубокого обучения в оценке состояния бортовых систем имеет несколько преимуществ. Во-первых, они могут обрабатывать различные типы данных, включая структурированные, неструктурированные и временные ряды. Во-вторых, нейронные сети могут

автоматически извлекать признаки из сырых данных, что освобождает от необходимости ручного определения признаков. В-третьих, глубокое обучение позволяет создавать модели с высокой степенью сложности, способные улавливать даже тонкие особенности и зависимости в данных.

Применение нейронных сетей и глубокого обучения в оценке состояния бортовых систем может включать различные архитектуры, такие как сверточные нейронные сети (CNN), рекуррентные нейронные сети (RNN) и глубокие нейронные сети (DNN). Эти архитектуры могут быть применены для задач классификации, регрессии, детектирования аномалий и прогнозирования состояния системы[26,27].

Нейронные сети и глубокое обучение имеют большой потенциал для улучшения точности и надежности оценки состояния бортовых систем. Однако их эффективное применение требует достаточного объема данных для обучения модели, а также вычислительных ресурсов для обучения и инференса. Кроме того, требуется тщательное проектирование и настройка модели для достижения оптимальных результатов.

- Методы ансамблей

Методы ансамблей являются мощным инструментом в машинном обучении, который объединяет несколько моделей для получения более точных и устойчивых прогнозов или оценок. Они основаны на принципе комбинирования прогнозов от нескольких базовых моделей с целью снижения ошибок и повышения обобщающей способности.

Один из наиболее популярных методов ансамблей - это случайный лес. Он состоит из набора решающих деревьев, где каждое дерево строится на случайной подвыборке данных и случайном подмножестве признаков. Конечный прогноз получается путем усреднения прогнозов всех деревьев.

Случайный лес обладает способностью эффективно обрабатывать большие объемы данных, обнаруживать важные признаки и обеспечивать хорошую устойчивость к переобучению.

Еще один популярный метод ансамблей - это градиентный бустинг. Он основан на итеративном построении слабых моделей, которые последовательно добавляются в ансамбль, с каждой новой моделью исправляющей ошибки предыдущих моделей. Градиентный бустинг строит сильную модель, объединяя прогнозы слабых моделей с использованием градиентного спуска. Этот метод обладает высокой предсказательной способностью и может обрабатывать различные типы данных.

Преимущества методов ансамблей включают высокую точность прогнозирования, устойчивость к шуму и способность обрабатывать сложные зависимости в данных. Они также могут обнаруживать важные признаки и автоматически выбирать наиболее информативные признаки для моделирования[28].

Однако методы ансамблей могут быть требовательны к вычислительным ресурсам и времени обучения, особенно для больших наборов данных или сложных моделей. Также важно аккуратно настраивать гиперпараметры моделей ансамблей для достижения оптимальной производительности и избежания переобучения.

В итоге, методы ансамблей, такие как случайный лес и градиентный бустинг, предоставляют эффективные и мощные инструменты для оценки состояния бортовых систем, объединяя прогнозы нескольких моделей и улучшая качество прогнозов.

- Гибридные методы

Гибридные методы машинного обучения представляют собой комбинацию двух или более различных методов с целью улучшения обобщающей способности и эффективности моделей. Эти методы объединяют различные подходы и техники, чтобы достичь более точных и надежных результатов, чем каждый отдельный метод в отдельности. В качестве достоинств можно выделить возможность использования сильных сторон различных методов, улучшение обобщающей способности модели и более точное предсказание. Однако, недостатками гибридных методов могут быть сложность выбора и настройки сочетания методов, а также увеличение вычислительной сложности при использовании нескольких алгоритмов одновременно.

Гибридные методы машинного обучения могут использовать комбинацию методов обучения с учителем, без учителя и с подкреплением, а также других методов, в зависимости от конкретной задачи и требований. Вот несколько примеров гибридных методов:

1. Стекинг (stacking): Это метод, в котором прогнозы нескольких базовых моделей сначала объединяются, а затем используются в качестве входных данных для метамодели. Метамодель обучается использовать прогнозы базовых моделей для получения итогового прогноза. Стекинг позволяет комбинировать различные модели и использовать их сильные стороны для улучшения качества предсказаний.

2. Бэггинг и бустинг: Гибридные подходы также могут комбинировать методы бэггинга и бустинга для создания более мощных моделей. Например, можно применить градиентный бустинг над ансамблем случайных лесов или использовать случайный лес в качестве базовых моделей для градиентного бустинга. Это позволяет сочетать преимущества обоих методов и достичь лучших результатов.

3. Гибридные нейронные сети: В глубоком обучении также применяются гибридные методы, которые комбинируют различные типы нейронных сетей или архитектуры для решения сложных задач. Например, можно использовать комбинацию сверточных нейронных сетей (Convolutional Neural Networks, CNN) и рекуррентных нейронных сетей (Recurrent Neural Networks, RNN) для обработки изображений и последовательных данных одновременно.

Гибридные методы машинного обучения позволяют использовать сильные стороны различных методов и подходов для достижения лучших результатов при оценке состояния бортовых систем. Они требуют тщательной настройки и адаптации для конкретных задач и данных, но при правильном применении могут значительно повысить качество прогнозов и анализа.

## 2.2 Преимущества и ограничения применимости методов МО в МИС

### Вычислительные затраты и ресурсоемкость

- Выбор методов машинного обучения с учетом вычислительных ограничений МИС

При выборе методов машинного обучения для применения в морских информационных системах (МИС), необходимо учитывать вычислительные ограничения, связанные с ресурсоемкостью и доступностью вычислительной мощности на борту судна или в ограниченном морском окружении. Вот некоторые аспекты, которые следует учесть при выборе методов МО с учетом вычислительных ограничений МИС:

1. Необходимо учитывать вычислительную эффективность алгоритмов и возможности доступной вычислительной инфраструктуры на борту судна или в морской среде.

2. Оптимизация моделей – сокращение размерности данных, удаление ненужных признаков или применение аппроксимации моделей.

3. Выбор методов МО должен учитывать специфику морской среды и требования МИС. Например, можно использовать методы с учетом временных рядов, пространственной корреляции или учетом неопределенности данных.

4. Возможность использования распределенных вычислительных ресурсов для улучшения производительности и эффективности МО – распределение вычислений между несколькими узлами, использование параллельных алгоритмов или применение облачных вычислений[29].

- Оптимизация и ускорение вычислительных процессов для применения в МИС

При применении методов машинного обучения в морских информационных системах (МИС), важным аспектом является оптимизация и ускорение вычислительных процессов. Это позволяет обеспечить более эффективное использование ресурсов и достичь более быстрой обработки данных, что особенно важно в реальном времени.

Вот некоторые подходы и методы, которые могут быть применены для оптимизации и ускорения вычислительных процессов в МИС:

1. Использование параллельных вычислений
2. Применение аппаратного ускорения, такого как графические процессоры (GPU) или специализированные процессоры (например, тензорные процессоры)
3. Предварительное вычисление и кэширование результатов с целью сокращения времени выполнения вычислений при повторных запросах или обработке данных.
4. Использование распределенных систем.

## Недостаток данных и избыточность данных:

- Анализ и решение проблемы нехватки данных для обучения моделей в МИС

Одной из распространенных проблем при применении методов машинного обучения в морских информационных системах (МИС) является нехватка данных для обучения моделей. Недостаток данных может возникать из-за различных причин, таких как сложность сбора данных, ограничения доступа к данным или недостаточное количество событий, которые требуется обучить модель.

Для решения проблемы нехватки данных в МИС можно применить различные аналитические и технические подходы, такие как анализ полноты и качества имеющейся выборки, увеличение объема путем генерации новых образцов данных, синтез данных и т.д.

В целом, анализ и решение проблемы нехватки данных требуют тщательного подхода и комбинации различных методов. Цель состоит в том, чтобы использовать имеющиеся данные максимально эффективно и обеспечить надежную оценку состояния бортовых систем в МИС.

- Работа с избыточными данными и их влияние на качество моделей в МИС

Избыточность данных также может быть проблемой при использовании методов машинного обучения в морских информационных системах (МИС). Избыточные данные могут включать повторяющуюся информацию, выбросы, шумы или несбалансированность классов. Это может негативно сказаться на качестве моделей и точности оценки состояния бортовых систем.

Для работы с избыточными данными и улучшения качества моделей можно применить различные подходы, в том числе препроцессинг данных,

выбор репрезентативных образцов, применение L1 или L2 регуляризации и т.д.

Работа с избыточными данными требует тщательного анализа и применения соответствующих методов обработки данных. Цель состоит в том, чтобы избежать искажений и неправильных выводов, а также обеспечить качественную оценку состояния бортовых систем в МИС.

Свойства данных и их распределение:

При выборе и применении методов машинного обучения (МО) в морских информационных системах (МИС) необходимо учитывать свойства обрабатываемых данных, такие как мультимодальность, гетерогенность, особенности распределения, уделять особое внимание разметке данных.

При работе с морскими информационными системами (МИС) возникает необходимость адаптировать модели машинного обучения (МО) к различным типам данных и их распределениям. Различные типы данных в МИС могут иметь разные характеристики и требования к моделированию [30].

Некоторые методы и подходы к адаптации моделей МО к различным типам данных и их распределениям в МИС включают:

1. Преобразование данных. Например, для данных с неравномерным распределением можно применить логарифмическое преобразование или стандартизацию данных. Для временных рядов могут использоваться методы сглаживания или декомпозиции.

2. Инженерия признаков – создание новых признаков на основе исходных данных.

3. Разработка и применение специализированных моделей, учитывающих особенности и свойства обрабатываемых данных.

4. Оптимизация параметров модели МО.

Адаптация моделей МО к различным типам данных и их распределениям в МИС является важным шагом для достижения точных и надежных результатов оценки состояния бортовых систем. Это позволяет

учесть особенности данных, повысить качество моделей и обеспечить более эффективное использование МО в МИС.

### 2.3 Повышение качества оценки состояния бортовых систем за счет сегментирования выборки данных

Разбиение данных на сегменты может проходить как в автоматическом, так ручном режимах. Одним из подходов к автоматическому разбиению данных на сегменты является использование алгоритмов кластеризации. Кластеризация позволяет группировать данные на основе их схожести или близости в многомерном пространстве. При этом данные, находящиеся в одном кластере, имеют схожие характеристики или поведение.

Для автоматического разбиения данных на сегменты можно использовать различные алгоритмы кластеризации, такие как алгоритм k-средних, иерархическая кластеризация, DBSCAN и другие. Каждый из этих алгоритмов имеет свои особенности и подходит для разных типов данных и задач.

При автоматическом разбиении данных на сегменты необходимо осуществить анализ и выбор наиболее релевантных признаков, определение числа кластеров (при помощи ряда эвристик или эмпирически), а также оценить качество полученного разбиения, например, вычислить значения коэффициента силуэта.

Автоматическое разбиение данных на сегменты позволяет более точно анализировать различные подмножества данных и применять к ним соответствующие методы анализа и моделирования. Это способствует улучшению оценки состояния бортовых систем.

Ручное разбиение данных на сегменты является альтернативным подходом к автоматическому разбиению данных на сегменты. В этом случае разделение данных производится вручную с участием эксперта, который принимает решения на основе своего знания предметной области и опыта.

Процесс ручного разбиения данных на сегменты включает следующие шаги:

1. Определение критериев разбиения.
2. На основе определенных критериев эксперт производит анализ данных и ручное разделение на сегменты.
3. После выполнения ручного разбиения данных важно произвести валидацию полученных сегментов. Ручное разбиение данных на сегменты имеет свои преимущества и недостатки. Среди преимуществ можно отметить экспертное знание, позволяющее учесть опыт и знания специалиста, осуществляющего сегментацию, а также гибкость к требованиям и особенностям предметной области. С другой стороны, любая ручная сегментация субъективна, трудоёмка и, как правило, полученная модель сложно масштабируема.

Таким образом, ручное разбиение данных на сегменты представляет собой важный метод при повышении качества оценки состояния бортовых систем, который позволяет учесть экспертное мнение и специфику предметной области, но требует дополнительных ресурсов и может быть ограничено в масштабируемости.

После разделения данных на сегменты, следующим шагом в повышении качества оценки состояния бортовых систем является обучение моделей для каждого сегмента данных. Каждый сегмент рассматривается как отдельный набор данных, для которого обучается своя модель машинного обучения.

В рамках предлагаемого подхода для обработки динамических информационных потоков предлагается агрегировать алгоритмы машинного обучения в ансамбль, настраиваемый на свойства данных. Структурная схема формирования ансамбля представлена на рисунке 1 (дрейф концепта – эффект, при котором статистические свойства целевой переменной, которую пытается предсказать модель, меняются со временем непредвиденным образом;

верификация модели классификации – процесс проверки истинности, адекватности и корректности работы модели).

Информационный поток в ИТКС, представленный последовательностью данных, поступает на предварительную обработку. Происходит оценка свойств данных и разбиение выборки на отдельные сегменты с совпадающими свойствами данных. В результате множество  $X^q$  с учетом действия множества факторов  $V$  разбивается на подмножества  $X_1, X_2, \dots, X_m$ , каждое из которых имеет свойства, отличные от других.

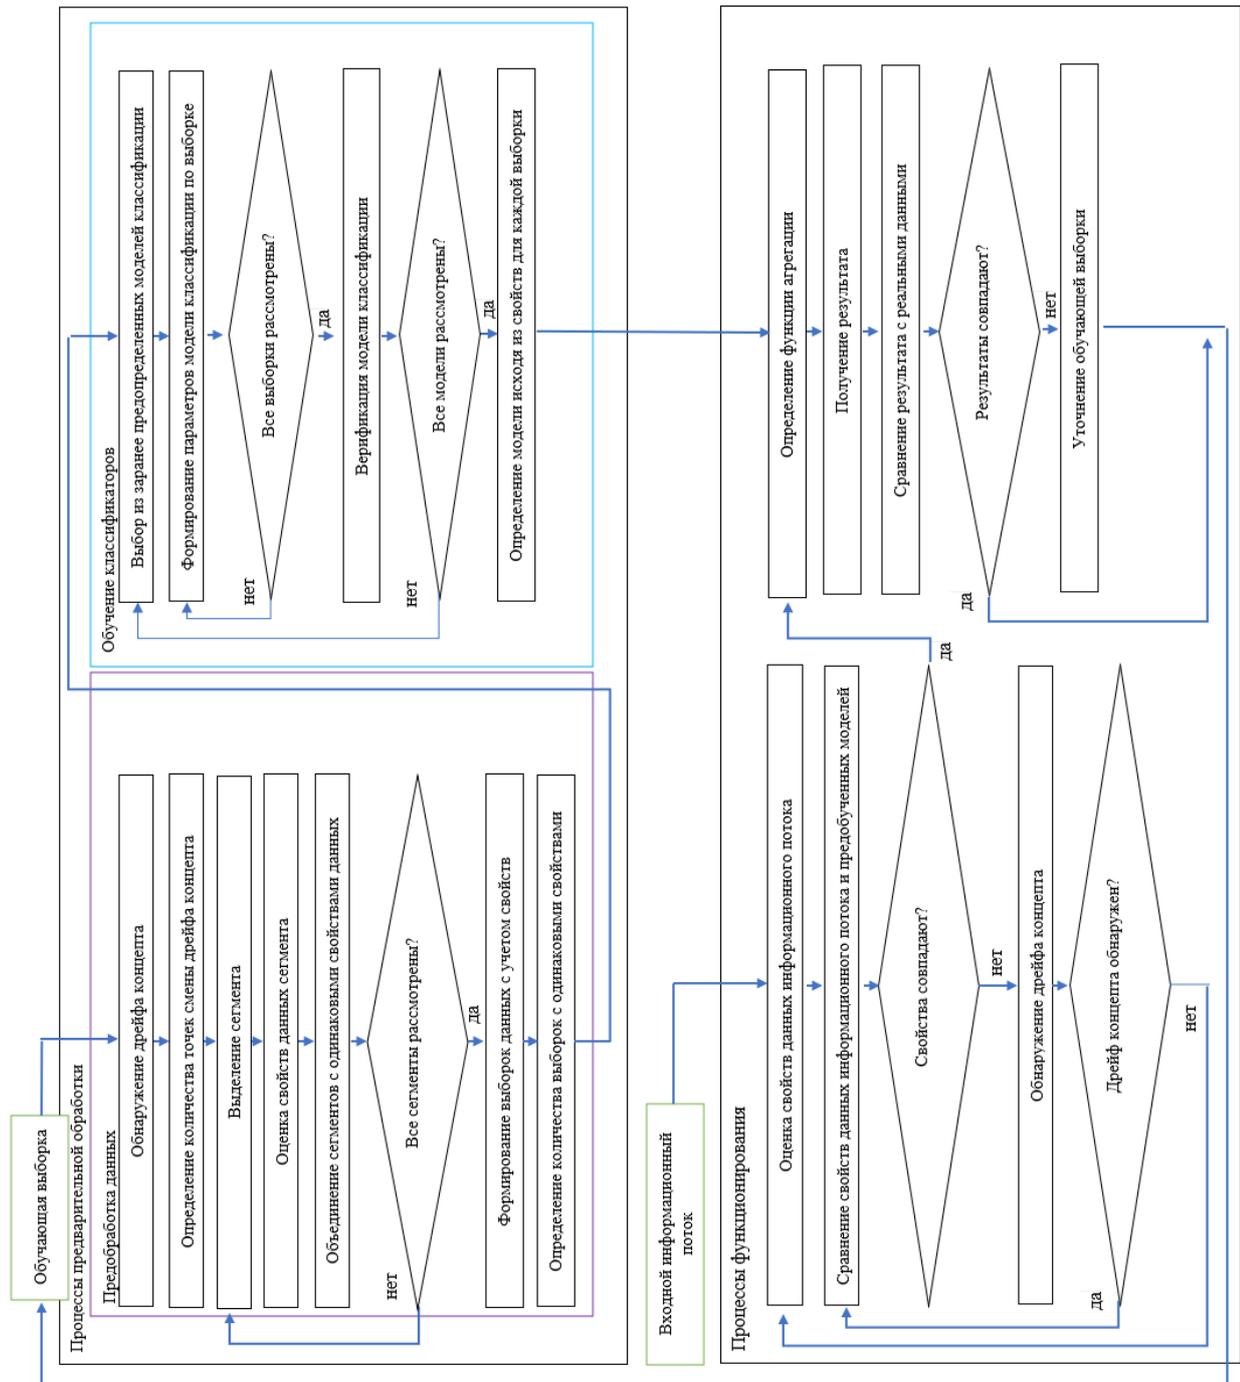


Рис. 1. Структурная схема формирования ансамбля классифицирующих алгоритмов, настраиваемого на свойства данных

Предобработка позволяет осуществить адаптивную настройку базовых классификаторов  $\{a_1, a_2, \dots, a_r\} \in A$  на каждом подмножестве  $X_i \in X^q$ . Происходит их обучение, направленное на формирование параметров и весовых матриц алгоритмов классификации, а затем проводится анализ их результатов. Выбор осуществляется исходя из минимизации эмпирического риска,

направленного на поиск алгоритма, для которого при  $x \in X^q$  соблюдается условие:

$$a(x) = \underset{a_i \in A}{\operatorname{argmin}} Q(a_i(x), X_i). \quad (3)$$

Используя выражение (3) для каждой подвыборки, становится возможным выбирать алгоритм с лучшими качественными показателями. Простая агрегирующая функция, вычисляющая лучшие алгоритмы на подвыборках  $X_1, X_2, \dots, X_m$  для выражения (3), примет вид:

$$a(x) = F(\underset{a_i \in A}{\operatorname{argmin}}(Q(a_1(x), X_1), \dots, a_r(x), X_1)), \dots, \underset{a_i \in A}{\operatorname{argmin}}(Q(a_1(x), X_m), \dots, a_r(x), X_m))). \quad (4)$$

В зависимости от решаемой задачи, заданных качественных показателей, а также от свойств данных и особенностей обучающих подмножеств, возможно формирование более сложных агрегирующих функций, учитывающих веса классификаторов и использующих аддитивные коэффициенты, изменяющие «важность голоса» алгоритма.

Полученный результат обработки в дальнейшем поступает в обучающую выборку и учитывается алгоритмом предобработки для уточнения модели.

Предложенный многоуровневый подход направлен на осуществление оценки возможных алгоритмов на предварительном этапе, и последующий выбор алгоритма и его агрегации с другими.

В ходе реализации сложных моделей машинного обучения возникает ряд проблемных вопросов, связанных с эффективностью применения отдельных ее компонент. Каждый базовый алгоритм обладает различными качественными показателями на данных с разными свойствами. В реальных системах с течением времени может происходить изменение частоты наблюдаемых событий, смещение диапазона значений, появление дисбаланса в совокупности данных. В связи с этим необходима разработка эффективных методов предобработки информации, направленных на вычисление и анализ свойств, поступающих на вход анализатора. Они должны выполнять не только обычные задачи

фильтрации, удаления шумов и выбросов, но и вычислять свойства данных, формировать их сегменты. Комплекс таких методов должен позволять осуществлять выбор и определение наиболее подходящих моделей для задач классификации и регрессии.

Применение методов основывается на предварительной обработке, где в первоначальной выборке происходит разграничение отдельных сегментов с данными, обладающими сходными свойствами. При автоматическом способе разделения вычисляются точки, в которых происходит изменение направления тренда, либо анализируются ситуации смены концепции.

Рассмотрим задачу машинного обучения, определенную в компактном пространстве  $X$  и меток  $C$ . Определим функционал качества  $Q$ , который позволяет оценить результат прогноза.

При обучении в рассматриваемом случае имеется дополнительная информация для ряда объектов наблюдений из генеральной совокупности, определенной в пространстве  $X'$ , которая доступна из обучающей выборки. То есть имеется доступ к объектам выборки, где распределение данных представляется в виде  $x_i, c_i \sim p(x|c)$ .

Учитывая класс функций  $a(x, w)$ , параметризованный весовыми коэффициентами  $w$ , необходимо найти решение следующей задачи оптимизации:

$$\min_w E_{x, c \sim p(x|c)} [Q(c, a(x, w))]. \quad (5)$$

На практике решение обозначенной задачи может быть осуществлено следующим образом. Первоначальная обучающая выборка обрабатывается классифицирующим алгоритмом, в сопряжении с которым работает метод детектора дрейфа концепта. Задача такой системы состоит в том, чтобы обнаружить ситуации, где происходит изменение плотности вероятности в анализируемых данных  $p_t(x|c) \neq p_{t+1}(x|c)$ . Задание порогов плотностей позволяет скомпоновать «близкие» области, свойства которых практически одинаковы. В результате исходная выборка делится на несколько частей с плотностями вероятностей  $p_1(x|c), p_2(x|c), \dots, p_n(x|c)$ . Эти выборки поступают

на вход классификационным алгоритмам  $a_1, a_2, \dots, a_r$ , где возможно их обучение и последующий выбор для каждого обучающего подмножества с учетом условия  $Q(a_i, X_i) \rightarrow \min$ .

После этого первоначальная классификация, позволяющая выбрать модели обработки данных, заканчивается.

Функционирование системы в динамике предполагает наличие поступающего на вход информационного потока данных  $x'$ . Он принимается детектором потока, в котором задается ширина окна и происходит сравнение временных рядов  $x'_{t_1}, \dots, x'_{t_1+T}$  и  $x_{t_1}, \dots, x_{t_1+T}$ , осуществляется оценка их свойств  $p_{x'}(x'|c)$  и  $p_x(x|c)$ . Затем выбирается наиболее подходящая классификационная модель, обученная на подмножестве, свойства которого максимально совпадают со свойствами информационного потока данных.

На последнем этапе модель используется для решения задач, полученные результаты обработки сравниваются с имеющимися, производится анализ результатов и формируются данные для выборки, которая может быть использована для уточнения процесса предварительного обучения.

В реальных системах возникают ситуации, когда появляются случайные факторы, изменяющие ее состояния. Часть из таких факторов возможно определить заранее, другая часть возникает случайно и не поддается прогнозированию. Однако в любом случае цена ошибки может быть очень высока.

В связи с этим необходимо прогнозирование и проактивное управление, направленное на оценку развития ситуации в динамике. Проактивное управление ИТКС позволяет осуществлять оценку состояния системы в динамике на несколько дискретов времени вперед, подразумевает оперативное реагирование и последующее недопущение возможных нештатных и аварийных ситуаций, предполагает предотвращение возникновения указанных ситуаций за счет создания в соответствующей системе управления принципиально новых прогнозирующих и упреждающих возможностей при формировании и реализации управляющих воздействий. Разбиение временных рядов на  $n$

отдельных сегментов позволяет определить их свойства  $p_{x'_i}(x'|c)$ , например плотности вероятностей появления событий.

Определяя интервальные допуски  $\varepsilon$  возможно сопоставление и принятие решения о совпадении анализируемых сегментов  $p_{x'_i}(x'|c) <> \varepsilon$  В результате можно выявить их последовательности, порядок следования друг за другом.

Обработка последовательностей дает возможность строить графы и матрицы переходов. Анализ переходов состояний делает возможным в текущий дискретный момент времени определять наиболее вероятные переходы из текущего состояния в последующие.

Для повышения вероятностей переходов возможно применение трендов полученных при анализе сегментов, описанных временными рядами.

Вывод:

Во второй главе работы было исследовано применение методов машинного обучения (МО) при оценке состояния бортовых систем в контексте морских информационных систем (МИС). В рамках этой главы были рассмотрены различные аспекты, связанные с повышением качества оценки состояния бортовых систем за счет сегментирования выборки данных, а также преимущества и ограничения существующих подходов и методов МО.

В пунктах 2.2 было представлено разделение данных на сегменты и применение методов МО для каждого сегмента. Были рассмотрены автоматическое и ручное разбиение данных, обучение моделей для каждого сегмента, выбор и оптимизация методов МО, агрегация результатов моделей и учет взаимосвязей между сегментами. Этот подход позволяет улучшить точность и надежность оценки состояния бортовых систем, а также адаптировать модели к различным сценариям и условиям работы.

В пункте 2.3 были рассмотрены преимущества и ограничения существующих подходов. Были выделены вычислительные затраты и ресурсоемкость, проблема нехватки данных и избыточность данных, а также

свойства данных и их распределение. Более детально были рассмотрены методы МО, такие как регрессия, кластеризация, нейронные сети и ансамбли, их достоинства и недостатки в контексте МИС. Была также обсуждена адаптация методов МО к МИС, включая применение предварительного обучения, переноса обучения и учет специфических требований и задач МИС при разработке новых методов.

Основным результатом исследования второй главы является разработка и представление подхода, основанного на сегментировании выборки данных и адаптации методов МО к МИС, для повышения качества оценки состояния бортовых систем. Этот подход позволяет улучшить точность и надежность оценки состояния, а также адаптировать модели к различным сценариям и условиям работы.

Исследование преимуществ и ограничений существующих подходов в контексте МИС позволяет определить наиболее эффективные методы МО, учитывая вычислительные ограничения, доступность данных и их свойства. Это помогает выбрать подходящие методы МО и оптимизировать вычислительные процессы для применения в МИС.

В целом, вторая глава работы проливает свет на применение методов МО при оценке состояния бортовых систем в МИС. Исследованные подходы и методы предоставляют ценные инструменты для повышения качества оценки состояния, обеспечивая точность, надежность и адаптивность моделей в различных сценариях работы. Однако следует учитывать преимущества и ограничения каждого метода и подхода, а также особенности данных и требования МИС, чтобы выбрать наиболее эффективное решение.

## ГЛАВА 3. АДАПТИВНОЕ ПРИМЕНЕНИЕ МОДЕЛЕЙ МАШИННОГО ОБУЧЕНИЯ ПРИ ОЦЕНКЕ СОСТОЯНИЯ ИБ БОРТОВЫХ СИСТЕМ

### 3.1 Формирование сегментов выборки данных и их обработка методами МО

Большинство задач регрессии и предсказания связаны с анализом информационных потоков. Обработка последовательностей и временных рядов имеет определенные особенности. В простейших случаях поступающие данные образуют размеченную выборку, над которой реализуются различные методы обучения. Такие подходы хорошо отражены в классических работах по искусственному интеллекту, в течение длительного времени они подвергались всесторонней оценке и имеют проработанную технологию внедрения и использования. Однако в случае изменения данных и их свойств возникает необходимость поддерживать заданные качественные показатели алгоритмов, что может являться трудоемкой задачей.

Огромное количество решений задач классификации, регрессии, предсказания поведения системы в динамике использует представление информационных потоков временной последовательностью. Появление моделей и методологий ARMA, ARIMA и других позволило существенно повысить точность прогнозов временного ряда. Однако их построение требует знаний о природе последовательности. Возникает необходимость ее перенастройки при появлении новых данных. Требуется постоянная оценка и подбор различных параметров для достижения заданной точности.

Современная парадигма машинного обучения состоит в том, что модели учатся непосредственно на данных, автоматически вычисляя и оценивая возникающие в выборках закономерности. Поэтому для достижения качественных показателей приходится особое внимание уделять данным.

В работах акцентируется внимание на ряде проблемных вопросов формирования кортежей признаков, создания паттернов поведения, которые подаются на вход классифицирующих алгоритмов. Такие подходы изначально

используют статическое представление информации, что не всегда оправдано, особенно для информации, поступающей от реальных систем. Одновременно с этим необходимо решать вопросы длины последовательности; определять характеристики алгоритмов, на основе которых будет производиться разделение выборки; оценивать влияние изменения распределений, частоты событий, дисбаланса классов.

При обработке данных имеют место вопросы влияния производительности и скорости алгоритмов анализа на качество результатов. В работе предложена оригинальная каскадная модель, элементами которой являются классифицирующие алгоритмы. Однако в ней возрастает сложность агрегации результатов. В ряде других исследований отмечается, что особую важность приобретает выделение наиболее информативных признаков, которые вносят основной вклад в задачах классификации и регрессии. Снижение размерности признакового пространства, например методом главных компонент, подсчетом информативности на основе энтропии, частотными методами и т. д., не всегда возможно, в частности, когда имеется одномерный временной ряд. Сокращение размерности признакового пространства позволяет повысить скорость обработки, но с течением времени в случае возникновения эффекта «дрейфа концепта» свойства признаков могут меняться, что приведет к устареванию классифицирующей модели.

В связи с этим возникает необходимость разработать методы и алгоритмы, направленные на повышение качественных показателей моделей в условиях изменения свойств данных.

В задачах машинного обучения основным проблемным вопросом остается формирование выборок данных. На практике возникают ситуации, когда в ходе функционирования ИТКС изменяются свойства трафика. Например, в зависимости от количества абонентов в сети происходит изменение объема в дневные и ночные часы. Отдельные сложности для классифицирующих алгоритмов вызывает неоднородное признаковое пространство, при формировании которого учитываются различные сообщения и их внутренняя

структура. Одинаковые сообщения, имеющие различные флаги, указывают на возникновение разных событий в сети. Одновременно с этим по мере функционирования системы могут происходить изменения диапазонов и распределений исследуемых переменных.

Полученные в таких условиях выборки данных не всегда репрезентативно отражают распределения событий, что может приводить к эффекту «разброса» ответов и влиять на качество процессов машинного обучения для сетевого трафика.

Кортеж значений  $X = (x_1, \dots, x_n)$ , характеризующий сетевой трафик, имеет множество параметров. В ходе функционирования системы в течение определенного момента времени может увеличиваться частота как информационных, так и служебных сообщений с различными флагами. Например, появление относительно большого количества сообщений конфигурации сети, может говорить о возможной попытке подключения к сети. А это, в свою очередь, дает информацию для того, чтобы определить легальность данных попыток. На основе количественных характеристик, используя размеченную выборку, основанную на «историческом» опыте, возможно определить нормальное и аномальное состояние.

Обозначим  $\{c_1, c_2\} = c$  метки нормального и аномального состояния ИТКС.

Количественные значения атрибутов  $x_1, \dots, x_n$  являются предикторами, на основе анализа значений которых, необходимо наиболее точно соотнести конкретный объект  $s$  к своей группе – нормальному  $c_1$  или аномальному  $c_2$  состоянию. В таком случае идентификация состояния ИТКС рассматривается как задача машинного обучения, определенная в компактном пространстве  $X$  и меток  $c$ , предполагающая создание алгоритма:

$$\mu: X \rightarrow c. \quad (1)$$

В целях определения качественных показателей классификатора  $\mu$  (1) определим функцию потерь  $L$ , которая сравнивает прогноз с меткой.

Применение метода можно рассмотреть для классификационных задач. В качестве функции для измерения потерь алгоритма классификации  $\mu(x_i)$ , действующего на выборке  $X^p$  (где  $p$  - количество кортежей выборки), рассмотрим индикатор ошибок:

$$I(x, \mu) = [c_j \neq \mu(x_i)]. \quad (2)$$

Частота ошибок (2) алгоритма  $\mu(x)$ , используемая для анализа потерь, определяется выражением:

$$L(\mu, X^p) = \frac{1}{p} \sum_{i=1}^p I(c_j, \mu(x_i)). \quad (3)$$

На регистрируемые данные осуществляют воздействие факторы  $V$ . Они могут быть определены явно. Например, рабочее и нерабочее время, может оказывать существенное влияние на объем сетевого трафика. Однако ввиду возможного одновременного воздействия не всегда удается однозначно их интерпретировать, что приводит к необходимости анализа выборки данных автоматическими методами, например, поиска разладки сигнала или обнаружения дрейфа концепта.

Влияние внешних и внутренних факторов на ИТКС приводит к тому, что выборка данных становится неоднородной, а неоднородности возникают в результате воздействия факторов.

Для повышения качественных показателей методов машинного обучения, на которые влияют выбросы данных, шумы, изменения плотности вероятности возникновения событий необходимо разбивать множество  $X^p$  на подмножества с учетом влияния на данные факторов  $v_i \in V, i = 1, \dots, m$ :

$$X^p = X_1^{p_1} \cup X_2^{p_2} \cup \dots \cup X_m^{p_m}, \sum_{i=1}^m p_i = p. \quad (4)$$

Тогда для каждого подмножества  $X_i^{p_i} \in X^p$ , где действует фактор или их совокупность  $v_i$  необходимо минимизировать функцию потерь:

$$L_i(\mu_i, X_i^{p_i}) \rightarrow \min. \quad (5)$$

Использование заранее выбранных алгоритмов классификации  $a_i \in A$ , на основании выражения (4) дает возможность определить для каждого сегмента  $X_i^{p_i}$  тот классификатор, который имеет лучшие значения функции потерь.

Потери на всей выборке необходимо минимизировать используя различные заранее predeterminedенные на каждом сегменте классификаторы.

$$\sum_{i=1}^m L_i(\mu_i, X_i^{p_i}) \rightarrow \min. \quad (6)$$

Применение выражения (6) на каждом сегменте выборки позволяет выбрать группу классификаторов, где каждый из них, имеет наилучшие показатели на predeterminedенном ему сегменте.

### 3.2 Экспериментальная оценка предложенного подхода

Предлагаемый подход был реализован на актуальных наборах данных (CIC IoT Dataset 2022, Bot-IoT Dataset, TON\_IoT Datasets, NSL-KDD), полученных из открытых источников. Анализируемые наборы данных представляют собой нормальный и аномальный трафик, содержащий различные сценарии кибератак на промышленные ИТКС, информацию о процессах функционирования IoT устройств и сенсоров в штатных и нештатных условиях. Анализ перечисленных наборов данных посвящен ряд актуальных работ различных зарубежных и отечественных исследователей, что позволяет сравнить полученные в рамках исследования результаты. Алгоритмы обработки тестовых данных были реализованы на языке Python с использованием библиотек pandas, numpy, sklearn. Для оценки изменений показателей качества было осуществлено два разбиения последовательности сетевого трафика: на основе индикаторной функции и на основе метода определения точек разладки. В дальнейшем для анализа алгоритмов классификации использовались выборки, полученные двумя способами разбиения.

С течением времени под воздействием внутренних и внешних факторов происходит изменение диапазонов целевой переменной. В рассматриваемых

случаях заранее известный фактор влияет на значения входящих в кортеж данных.

Оценка статистических свойств подмножеств на качество результатов моделей машинного обучения производилась с помощью различных алгоритмов: линейного дискриминантного анализа (LD), квадратичного дискриминантного анализа (QD), наивного байесовского классификатора (NB), ближайших соседей (KNN).

В первой части эксперимента проводилась сегментация набора данных NSL-KDD. В выборке NSL-KDD Test содержится 22544 записей, из них 9711 с классом нормального, 12833 аномального трафика. Выборка была разделена на две части – обучающую и тестовую. Структура данных содержит более 40 значений атрибутов.

В результате сетевой трафик был разбит на несколько сегментов, каждый из которых имеет свои свойства, связанные с трендом и статистическим размахом данных. Рассматривая требуемый показатель качества и используя выражение (5) можно выбрать тот классификатор, который покажет лучшие значения на сегменте, т.е. назначить на конкретный сегмент свой классификатор.

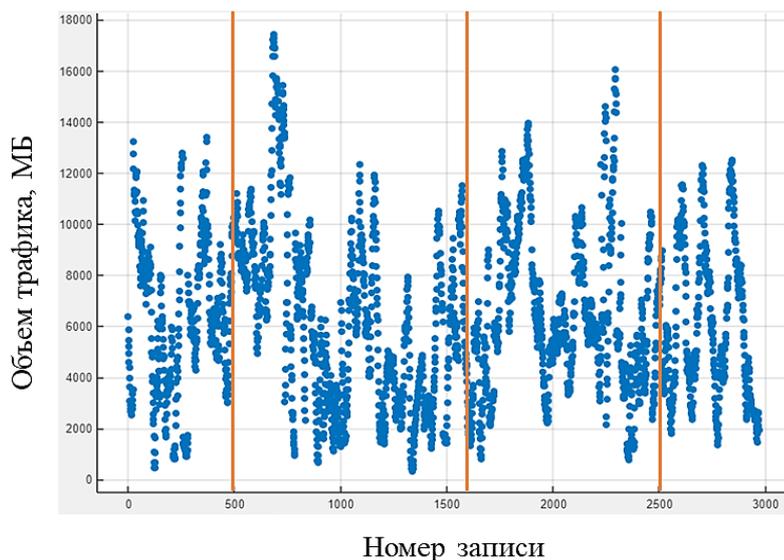


Рисунок 2. Определение точек изменения и границ сегментирования в многомерном представлении, по горизонтальной оси представлено время (time), по вертикальной оси объем данных (volume), передаваемых от источника к пункту назначения в одном соединении

Для оценки качества моделей и результатов исследования важно использовать соответствующие метрики. Метрики предоставляют количественные показатели эффективности моделей и помогают оценить точность и надежность полученных результатов. В случае исследования состояния бортовых систем могут использоваться следующие метрики:

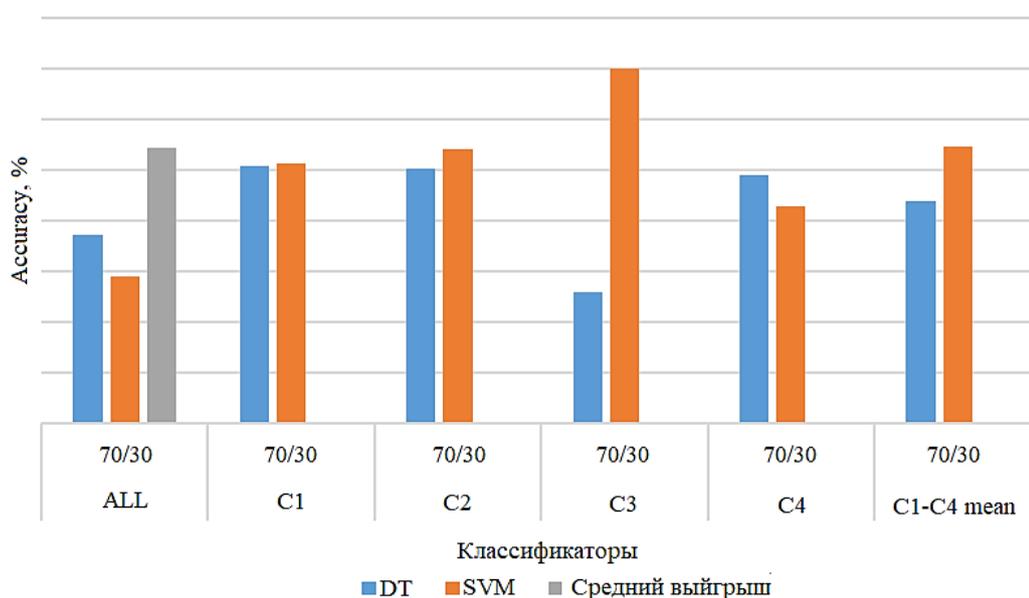
1. Точность (Accuracy): Эта метрика измеряет долю правильно классифицированных примеров от общего числа примеров. В контексте исследования состояния системы, например, нормального или неисправного, точность позволяет определить, насколько модель правильно классифицирует состояния.
2. Полнота (Recall): Полнота измеряет долю правильно идентифицированных положительных примеров (истинно положительных) от общего числа положительных примеров. В контексте исследования состояния системы это относится к способности модели обнаруживать неисправности или проблемы.
3. Точность предсказания (Precision): Точность предсказания определяет долю правильно классифицированных положительных примеров от общего числа положительно предсказанных примеров. Эта метрика показывает, насколько точно модель предсказывает положительные состояния системы.
4. F-мера (F1-score): F-мера является гармоническим средним между точностью и полнотой и объединяет обе эти характеристики модели. Она обеспечивает баланс между точностью и полнотой и часто используется для оценки состояния систем.
5. Коэффициент корреляции (Correlation coefficient): Коэффициент корреляции измеряет степень линейной связи между предсказанными значениями и реальными значениями. В контексте исследования состояния системы он может быть полезен для оценки корректности предсказания числовых показателей.

б. Площадь под ROC-кривой (AUC-ROC): Эта метрика используется для измерения качества классификации модели и ее способности разделять классы. AUC-ROC показывает вероятность правильного упорядочения случайно выбранного положительного и отрицательного примеров.

На выбор метрик влияют конкретные требования и особенности системы. Важно подобрать метрики, которые лучше всего отражают цели и требования исследования состояния бортовых систем. Также необходимо учитывать, что выбранные метрики должны быть чувствительными к изменениям и отражать важные аспекты безопасности и надежности работы системы.

На рисунке 2 представлены показатели по всей выборке целиком, по сегментам, и средние значения, полученные при выборе наилучших классификаторов.

Анализ гистограмм показывает, что, используя сегментацию выборки и назначая классификаторы, имеющие лучшие показатели качества, возможно повысить качество обработки всей выборки.



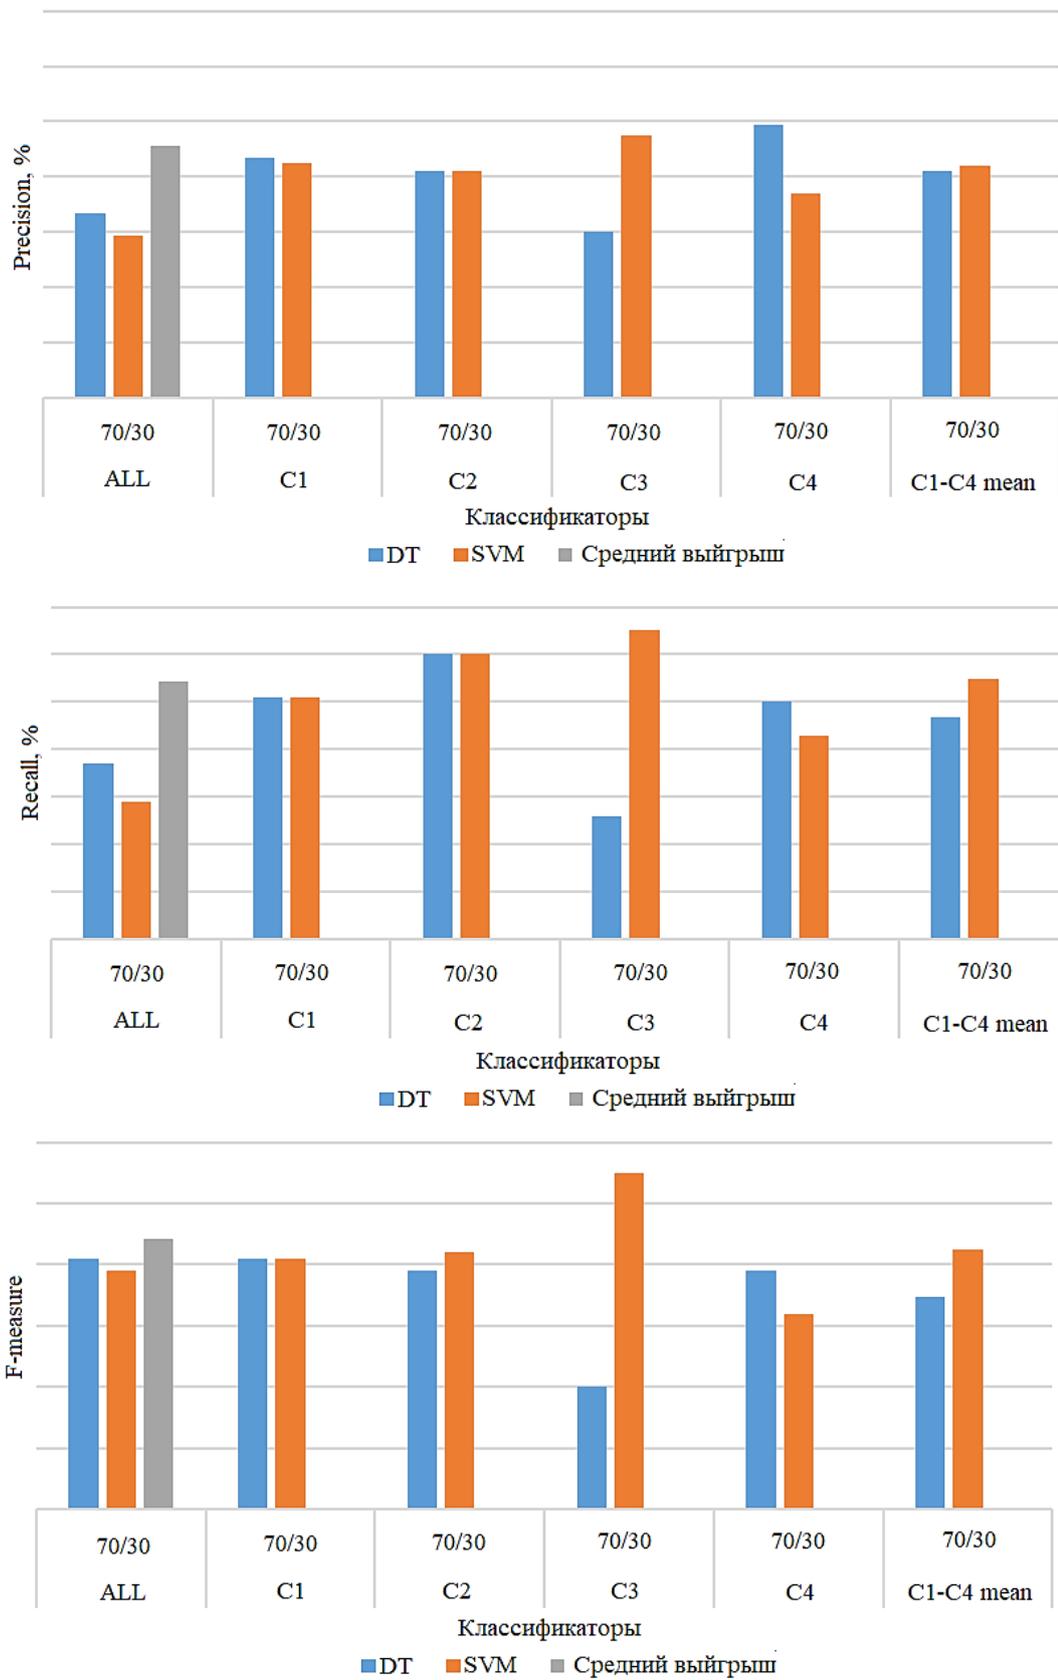


Рисунок 3. Качественные показатели классификации

Разделение последовательностей дает возможность бороться с выбросами и шумами и формировать компактно локализованные подмножества в пространстве объектов. Используя сегментацию можно повысить качественные показатели приблизительно на 5% по сравнению с выборкой в целом. Однако свойства данных, на которых обучаются и тестируются регрессионные модели, влияют на их эффективность.

В рамках второго этапа эксперимента тестировались все наборы данных. Ниже в таблице 1 приводятся результаты тестирования классификаторов (AUC – площадь под ROC-кривой, Accuracy – точность, F-мера – комплексный показатель эффективности). Сегментация была произведена по функции принадлежности и с помощью метода поиска точек разладки в автоматическом режиме осуществляет обнаружения момента, в котором происходит изменение направления тренда наблюдаемого процесса.

В анализируемых подвыборках наблюдался рост показателей качества классификации по сравнению с классификацией всего обучающего множества.

Результаты подтверждают, что сегментирование общей выборки, в основном, позволяет повысить определенные качественные показатели отдельных алгоритмов. Однако иногда возникают ситуации, ухудшающие результаты. Возникновение большого разброса, сложность построения разделяющей поверхности, могут негативно влиять на результаты отдельных классификаторов.

Таблица 1 – Результаты классифицирующих алгоритмов

|   |                | Вся<br>выборка | Сегментации<br>по функции<br>принадлежности |     |     |     | средн<br>ее | Сегментация по<br>методу поиска точек<br>разладки |     |     |     | средн<br>ее |
|---|----------------|----------------|---|-----|-----|-----|-------------|---|-----|-----|-----|-------------|
|   |                |                |   |     |     |     |             |   |     |     |     |             |
| D | F-<br>мера     | ,81            | ,84   | ,81 | ,82 | ,81 | ,82         | ,83   | ,82 | ,82 | ,8  | ,82         |
|   | Accurac<br>y % | 2,3            | 8,9   | 3,1 | 4   | 2,8 | 4,70        | 6   | 2,5 | 3,5 | 2,3 | 3,58        |

|    |                            |     |     |     |     |     |      |     |     |     |     |      |
|----|----------------------------|-----|-----|-----|-----|-----|------|-----|-----|-----|-----|------|
|    | UC <sup>A</sup>            | ,74 | ,79 | ,73 | ,75 | ,76 | ,76  | ,73 | ,74 | ,74 | ,76 | ,74  |
| D  | -мера <sup>F</sup>         | ,81 | ,84 | ,81 | ,82 | ,81 | ,82  | ,83 | ,82 | ,81 | ,81 | ,82  |
|    | сcurac<br>y % <sup>A</sup> | 2,3 | 8,2 | 2,2 | 4,2 | 3,4 | 4,50 | 5,3 | 2,7 | 3,3 | 3   | 3,58 |
|    | UC <sup>A</sup>            | ,74 | ,79 | ,73 | ,75 | ,76 | ,76  | ,74 | ,75 | ,74 | ,77 | ,75  |
| NN | -мера <sup>F</sup>         | ,79 | ,81 | ,51 | ,8  | ,78 | ,73  | ,8  | ,62 | ,79 | ,78 | ,75  |
|    | сcurac<br>y % <sup>A</sup> | 0,5 | 7,6 | 2,4 | 2,9 | 2,3 | 3,80 | 5,7 | 1   | 1,6 | 2,1 | 2,60 |
|    | UC <sup>A</sup>            | ,71 | ,79 | ,72 | ,74 | ,76 | ,75  | ,76 | ,72 | ,71 | ,76 | ,74  |
| B  | -мера <sup>F</sup>         | ,79 | ,84 | ,81 | ,81 | ,81 | ,82  | ,83 | ,82 | ,8  | ,8  | ,81  |
|    | сcurac<br>y % <sup>A</sup> | 1,4 | 6,1 | 3,3 | 3,6 | 2,6 | 3,90 | 3,5 | 3,4 | 1,5 | 2,2 | 2,65 |
|    | UC <sup>A</sup>            | ,74 | ,78 | ,73 | ,75 | ,76 | ,76  | ,73 | ,74 | ,74 | ,76 | ,74  |

Над набором данных возможно осуществить дальнейшее разбиение на подмножества, повышая порог, идентифицирующий смену концепции или, для эвристических методов, используя информацию о выходных и праздничных днях, условиях и т.д. Решение можно применять как дополнение к различным моделям.

Предложенный метод подготовки данных можно применить для улучшения качественных показатели регрессии. Для оценки влияния подмножеств на качество результатов моделей машинного обучения были выбраны различные алгоритмы: линейной регрессии (LD), гауссовой регрессии (GR), деревьев решений (DT), метода опорных векторов (SVM).

Рассматривались задача предсказания интенсивности сетевого трафика, при условии известных значений рабочего или нерабочего времени. Значения функции потерь (RMSE (Root Mean Square Error) – среднеквадратическая ошибка) для различных сегментов представлено в таблице 2.

В случае применения сегментации в среднем наблюдается уменьшение значений функции потерь по сравнению с полной не сегментированной выборкой.

Таблица 2. Результаты функции потерь RMSE для разных классификаторов

| MSE | Вся выборка | Сегментации по функции принадлежности |     |     |     | Среднее | Сегментация по методу поиска точек разладки |     |     |     | Среднее |
|-----|-------------|---------------------------------------|-----|-----|-----|---------|---|-----|-----|-----|---------|
|     |             |                                       |     |     |     |         |   |     |     |     |         |
| R   | ,36         | ,55                                   | ,65 | ,33 | ,60 | ,53     | ,25   | ,93 | ,08 | ,52 | ,45     |
| R   | ,03         | ,34                                   | ,60 | ,31 | ,59 | ,46     | ,03   | ,90 | ,06 | ,49 | ,37     |
| T   | ,37         | ,10                                   | ,10 | ,77 | ,01 | ,99     | ,83   | ,40 | ,55 | ,97 | ,94     |
| VM  | ,90         | ,56                                   | ,65 | ,33 | ,61 | ,54     | ,26   | ,93 | ,08 | ,53 | ,45     |

### Вывод

В третьей главе ВКР было исследовано применение сегментации данных в задачах классификации и регрессии. Целью исследования было определить эффективность данного подхода и его влияние на качество моделей машинного обучения.

В ходе эксперимента были использованы различные алгоритмы классификации, такие как линейная регрессия (LD), гауссова регрессия (GR), деревья решений (DT) и метод опорных векторов (SVM). Также были проведены оценки функции потерь (RMSE) для каждого из этих алгоритмов.

Результаты исследования показали, что применение сегментации данных положительно влияет на эффективность моделей. Общая выборка была разделена на сегменты с использованием двух методов: по функции принадлежности и по методу поиска точек разладки.

В случае классификации, результаты показали улучшение качества моделей на примерно 5% по сравнению с общей выборкой. В основном, сегментация данных привела к повышению показателей точности (Accuracy) и

площади под ROC-кривой (AUC) для отдельных алгоритмов. Однако, некоторые ситуации могли привести к ухудшению результатов из-за большого разброса или сложности разделяющей поверхности.

В случае регрессии, проведенное исследование показало, что сегментация данных также приводит к снижению функции потерь (RMSE) для алгоритмов линейной регрессии, гауссовой регрессии, деревьев решений и метода опорных векторов.

Выводы данного исследования указывают на значимость сегментации данных в задачах классификации и регрессии. Повышение качества моделей и снижение функции потерь свидетельствуют о том, что сегментация позволяет обнаруживать и учитывать различные тренды и концепции, присутствующие в данных.

Рекомендуется дальнейшее исследование в области применения сегментации данных, включая анализ других алгоритмов машинного обучения и факторов, таких как сезонность и внешние воздействия. Это позволит более полно понять преимущества и ограничения данного подхода и его применимость в реальных сценариях.

Также следует учитывать, что результаты исследования могут быть специфичны для конкретного набора данных и выбранных алгоритмов. Поэтому рекомендуется проводить дополнительные эксперименты и анализировать результаты для различных данных и алгоритмов, чтобы получить более обобщенные выводы.

## ЗАКЛЮЧЕНИЕ

В данной выпускной квалификационной работе были исследованы различные аспекты оценки состояния бортовых систем в контексте морских информационных систем (МИС) и применение методов машинного обучения (МО) для достижения этой цели.

В первой главе были подробно описаны бортовые системы, их составляющие и способы оценки их состояния. Были рассмотрены различные типы систем, включая навигационные, электронные, системы безопасности и энергетические системы. Также было представлено понятие "состояние узлов и устройств бортовых систем", их классификация и способы оценки, а также важные ГОСТы, связанные с оценкой надежности и информационной безопасности.

Заключительные пункты первой главы были посвящены постановке задачи, целям и методам исследования. Основной целью работы являлось улучшение надежности и безопасности бортовых систем. В работе были описаны подходы и методы, используемые для достижения этой цели, включая использование методов МО.

Во второй главе было исследовано применение методов МО при оценке состояния бортовых систем в контексте МИС. Были рассмотрены различные аспекты, связанные с повышением качества оценки состояния через сегментацию выборки данных. Были представлены различные методы разделения данных на сегменты, обучение моделей для каждого сегмента, выбор и оптимизация методов МО, агрегация результатов моделей и учет взаимосвязей между сегментами. В результате исследования был предложен подход, основанный на сегментировании выборки данных и адаптации методов МО к МИС, для повышения качества оценки состояния бортовых систем.

Третья глава была посвящена применению сегментации данных в задачах классификации и регрессии. В работе были использованы различные алгоритмы классификации, такие как линейная регрессия, гауссова регрессия, деревья решений и метод опорных векторов. Были проведены оценки функции потерь

для каждого из этих алгоритмов и сравнительный анализ их результатов. Также были рассмотрены алгоритмы регрессии, такие как логистическая регрессия и случайный лес, и была проведена оценка их точности. В результате исследования было показано, что сегментация данных может значительно улучшить качество оценки состояния бортовых систем.

В заключительной части работы было представлено обобщенное исследование всех трех глав. Были подведены итоги проведенного исследования и выделены основные результаты. Отмечается, что применение методов МО при оценке состояния бортовых систем в контексте МИС позволяет повысить точность, надежность и адаптивность моделей в различных сценариях работы. Выводится заключение о значимости исследования для области морских информационных систем и подчеркивается его вклад в развитие технологий оценки состояния бортовых систем.

Таким образом, данная выпускная квалификационная работа представляет важный вклад в область оценки состояния бортовых систем в контексте МИС. Исследования, проведенные в работе, позволяют лучше понять принципы и методы оценки состояния, а также предлагают эффективные подходы и методы на основе машинного обучения. Результаты работы могут быть использованы в инженерной практике для повышения надежности, безопасности и эффективности бортовых систем в морских информационных системах.

Практическая значимость и применимость исследования: В работе были предложены новые подходы и методы оценки состояния бортовых систем, основанные на применении методов машинного обучения и сегментации данных. Эти методы могут быть полезны и применимы в различных областях, включая судостроение, авиация, автомобильную промышленность и другие сферы, где требуется надежная оценка состояния систем для обеспечения безопасности и эффективности работы. Ограничения и дальнейшие направления исследования: В ходе работы могли выявиться определенные ограничения и ограничивающие факторы, которые могут повлиять на применимость предложенных методов. Например, ограниченная доступность

данных, сложность взаимосвязей между различными сегментами данных, вычислительные ограничения и другие факторы. Дальнейшие исследования могут быть направлены на преодоление этих ограничений и разработку более точных и эффективных методов оценки состояния.

Практическая реализация и внедрение результатов: Важным аспектом работы является применение полученных результатов в практических условиях. Для этого может потребоваться дальнейшая разработка программного обеспечения, создание прототипов или проведение полевых испытаний. Отметьте в заключении возможности и пути внедрения разработанных методов в реальные системы, а также потенциальные выгоды, которые могут быть получены от их использования.

Значимость исследования в контексте актуальных тенденций: Отметьте, как исследование соответствует современным тенденциям и вызовам в области оценки состояния бортовых систем. Укажите на важность разработки надежных и безопасных систем в контексте развития автономных и интеллектуальных технологий, а также на потенциальный вклад вашей работы в решение данных проблем.

Подведение общих итогов и акцентирование основных достижений: В заключении следует подвести общие итоги работы и основные достижения, которые были получены в процессе исследования. Укажите на значимость результатов и их соответствие поставленным целям и задачам работы.

## СПИСОК ИСПОЛЬЗУЕМЫХ ИСТОЧНИКОВ

1. Сухопаров, М.Е. Адаптивное обучение моделей для прогнозирования потоков данных в информационно-телекоммуникационных системах / М.Е. Сухопаров, И.С. Лебедев, И.А. Сикарев // Информация и Космос. – 2022. – № 4. – С. 115–121.
2. Сухопаров, М.Е. Повышение качества анализа состояния безопасности телекоммуникационной системы при сегментации сетевого трафика / М.Е. Сухопаров, И.С. Лебедев, И.А. Сикарев, Б.Т. Рзаев // Т-Comm: Телекоммуникации и транспорт. – 2022. – Т. 16. – № 9. – С. 28–32.
3. Черняк Л. Киберфизические системы на старте // Открытые системы. 2014. № 2. С. 10–13.
4. Lee E.A., Neuendorffer S., Wirthlin M.J. Actor-Oriented Design of Embedded Hardware and Software Systems // J. Circuits, Syst. Comput. 2003. V. 12. P. 231–260.
5. Юсупов Р.М., Ронжин А.Л. От умных приборов к интеллектуальному пространству // Вестник Российской академии наук. 2010. Т. 80. № 1. С. 45–51.
6. Lebedev I., Korzhuk V., Krivtsova I., Salakhutdinova K., Sukhoparov M., Tikhonov D. Using preventive measures for the purpose of assuring information security of wireless communication channels // Conference of Open Innovation Association, FRUCT 18. Сер. "Proceedings of the 18th Conference of Open Innovations Association FRUCT and Seminar on Information Security and Protection of Information Technolog, FRUCT-ISPIT 2016" 2016. С. 167-173.
7. Бажаев Н.А., Кривцова И.Е., Лебедев И.С., Сухопаров М.Е. Моделирование информационного воздействия на удаленные устройства беспроводных сетей // Проблемы информационной безопасности. Компьютерные системы. 2016. № 3. С. 76-84.
8. Lebedev I.S., Korzhuk V.M. The Monitoring of Information Security of Remote Devices of Wireless Networks // Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics). 2015, Vol. 9247, pp. 3–10
9. Бажаев Н.А., Лебедев И.С., Кривцова И.Е. Анализ статистических данных мониторинга сетевой инфраструктуры для выявления аномального поведения локального сегмента системы // Научно-технический вестник информационных технологий, механики и оптики. 2017. Т. 17. № 1. С. 92-99.
10. Сухопаров М.Е., Лебедев И.С., Коржук В.М., Кривцова И.Е., Печеркин С.А. Обеспечение информационной безопасности каналов связи на основе многофункционального специализированного программно-аппаратного решения // Проблемы информационной безопасности. Компьютерные системы. 2016. Т. 2. С. 70-79.
11. Lebedev I., Krivtsova I., Korzhuk V., Bazhayev N., Sukhoparov M., Pecherkin S., Salakhutdinova K. The analysis of abnormal behavior of the system local segment on the basis of statistical data obtained from the network infrastructure monitoring // Lecture Notes in Computer Science. 2016. Т. 9870. С. 503-511.

12. Bazhayev, N., Lebedev, I., Korzhuk, V., Zikratov, I. Monitoring of the Information Security of Wireless remote devices // Source of the Document 9th International Conference on Application of Information and Communication Technologies, AICT 2015 - Proceedings 7338553, Pages 233-236

13. Nikolaevskiy I., Lukyanenko A., Polishchuk T., Polishchuk V.M., Gurtov A.V. isBF: Scalable In-Packet Bloom Filter Based Multicast // Computer Communications. 2015. Vol. 70, pp. 79–85

14. Shamir, E. Tramer. Acoustic cryptanalysis: on nosy people and noisy machines // Eurocrypt 2004 rump session, 2004

15. R. Ortega, A. Bobtsov, A. Pyrkin, S. Aranovskiy. A parameter estimation approach to state observation of nonlinear systems // Proceedings of the IEEE Conference on Decision and Control, pp. 6336-6341

16. Wyglinski A.M., Huang X., Padir T., Lai L., Eisenbarth T.R., Venkatasubramanian K. Security of autonomous systems employing embedded computing and sensors // IEEE Micro 33 (1) 2013, art. no. 6504448, pp. 80-86

17. Bazhayev N., Lebedev I., Korzhuk V., Zikratov I. Monitoring of the information security of wireless remote devices // 9th International Conference on Application of Information and Communication Technologies, AICT 2015 - Proceedings 9. 2015. C. 233-236

18. Wyglinski, A.M., Huang, X., Padir, T., Lai, L., Eisenbarth, T.R., Venkatasubramanian, K. Security of autonomous systems employing embedded computing and sensors // IEEE Micro 33 (1) 2013, art. no. 6504448, pp. 80-86

19. Сухопаров М.Е., Лебедев И.С. Метод выявления аномального поведения персональных сетей // Проблемы информационной безопасности. Компьютерные системы. 2017. № 1. С. 9–15.

20. Бажаев Н., Лебедев И.С., Кривцова И.Е. Анализ статистических данных мониторинга сетевой инфраструктуры для выявления аномального поведения локального сегмента системы // Научно-технический вестник информационных технологий, механики и оптики. 2017. Т. 17. № 1(107). С. 92–99.

Lebedev I.S., Bazhayev N., Sukhoparov M.E., Petrov V.I., Gurtov A.V. Analysis of the State of Information Security on the Basis of Serious

21. Krivtsova I., Lebedev I., Sukhoparov M., Bazhayev N., Zikratov I., Ometov A., Andreev S., Masek P., Fujdiak R., Hosek J. Implementing a broadcast storm attack on a mission-critical wireless sensor network // Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics). 2016. V. 9674. P. 297–308.

22. Emission Electronic Components // Proceedings of the 20th Conference of Open Innovations Association FRUCT. 2017. P. 216–221.

23. Матвеев Ю.Н., Симончик К.К., Тропченко А.Ю., Хитров М.В. Цифровая обработка сигналов. Учебное пособие по дисциплине "Цифровая обработка сигналов" // СПб: СПбНИУ ИТМО, 2013. – 166 с.

24. Горелик А. Л., Скрипкин В. А. Методы распознавания. Учебное пособие для вузов // М., «Высш. школа», 1977. - 222 с.

25. Lebedev I.S., Korzhuk V.M. The Monitoring of Information Security of Remote Devices of Wireless Networks // Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics). 2015, Vol. 9247, pp. 3–10
26. Сухопаров М.Е., Лебедев И.С. Метод выявления аномального поведения персональных сетей // Проблемы информационной безопасности. Компьютерные системы. 2017. № 1. С. 9-15
27. Lebedev I.S., Korzhuk V.M. The Monitoring of Information Security of Remote Devices of Wireless Networks // Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics) - 2015, Vol. 9247, pp. 3-10
28. M. Prabhakar, J. N. Singh, G. Mahadevan Nash equilibrium and Markov chains to enhance game theoretic approach for vanet security. // International Conference on Advances in Computing, ICAdC 2012; Bangalore, Karnataka; India; 4 July 2012 through 6 July 2012, Volume 174 AISC, 2013, pp 191-199
29. Chehri A., Hussein T. Moutah Survivable and Scalable Wireless Solution for E-health and Emergency Applications // In EICS4MED 2011. Proceedings of the 1st International Workshop on Engineering Interactive Computing Systems for Medicine and Health Care. Pisa, Italy. 2011. P. 25–2
30. Сухопаров М.Е., Лебедев И.С. Анализ состояния информационной безопасности на основе побочного излучения электронных компонент // Проблемы информационной безопасности. Компьютерные системы. 2017. № 2. С. 92–98.
31. Royackers L., Rinie van Est. A Literature Review on New Robotics: Automation from Love to War // International Journal of Social Robotics. November 2015. V. 7. Is. 5. P. 549–570.
32. Сухопаров М.Е., Лебедев И.С. Анализ состояния информационной безопасности на основе побочного излучения электронных компонент // Проблемы информационной безопасности. Компьютерные системы. 2017. № 2. С. 92-98
33. Смирнов Н.В., Дунин-Барковский И.В. Курс теории вероятностей и математической статистики для технических приложений. – М.: Издательство «Наука», 1969. – 512 с.
34. Rogachev G.N. Production method of describing automated controllers in the analysis of continuous-discrete control systems // Automatic control and computer sciences. 2014. V. 48. N 5. P. 249–256.
35. Лещев С.В. Электронная культура и виртуальная реальность: третья цифровая волна НБИК-парадигмы // Вестн. гуманитар. фак. Иванов. гос. хим.-технол. ун-та. 2014. Вып. 7. С. 5–9.
36. Nikolaevskiy I., Lukyanenko A., Polishchuk T., Polishchuk V.M., Gurtov A.V. isBF: Scalable In-Packet Bloom Filter Based Multicast // Computer Communications. 2015. V. 70. P. 79–85.
37. Krivtsova, I., Lebedev, I., Sukhoparov, M., Bazhayev, N., Zikratov, I., Ometov, A. , Andreev, S., Masek, P., Fujdiak, R., Hosek, J. Implementing a broadcast storm attack on a mission-critical wireless sensor network // Lecture Notes in Computer

Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics) Volume 9674, 2016, Pages 297-308.

38. Котенко И.В., Саенко И.Б. Создание новых систем мониторинга и управления кибербезопасностью // Вестник Российской академии наук. 2014. Т. 84. № 11. С. 993–1001.

39. Al-Naggar Y., Koucheryavy A. Fuzzy Logic and Voronoi Diagram Using for Cluster Head Selection in Ubiquitous Sensor Networks // Internet of Things, Smart Spaces, and Next Generation Networks and Systems. 14th International Conference, NEW2AN 2014 and 7th Conference, ruSMART 2014 Saint Petersburg, Russia, August 27–29, 2014, Proceedings. Springer, LNCS 8638, P. 319–330.