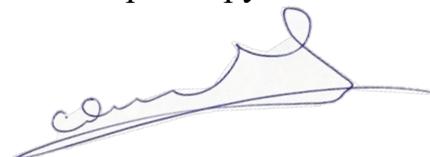


Федеральное государственное бюджетное образовательное учреждение высшего образования
«Московский государственный технический университет имени Н.Э. Баумана
(национальный исследовательский университет)»
(МГТУ им. Н.Э. Баумана)

На правах рукописи



Коцоев Константин Игоревич

**РАЗРАБОТКА ПРЕДИКТИВНЫХ МЕТОДОВ И АЛГОРИТМОВ ДЛЯ
СИСТЕМ ДИАГНОСТИРОВАНИЯ ОБОРУДОВАНИЯ АЭС С ВВЭР**

Специальность 2.4.9 – Ядерные энергетические установки, топливный
цикл, радиационная безопасность

ДИССЕРТАЦИЯ

на соискание ученой степени кандидата технических наук

Научный руководитель –
доктор технических наук, доцент
Перевезенцев Владимир Васильевич

Москва 2025

ОГЛАВЛЕНИЕ

ВВЕДЕНИЕ	4
Глава 1. Методы предиктивной аналитики для диагностирования РУ	14
1.1 Предварительная обработка данных.....	16
1.2 Обнаружение неисправностей.....	27
1.3 Прогнозирование технического состояния	35
1.4 Нейронные сети	38
1.5 Выводы к главе 1	47
Глава 2. Фильтрация глобальных шумов измерительных каналов систем контроля течи трубопроводов ГЦК РУ с ВВЭР	49
2.1 Формирование диагноза на основе анализа акустических сигналов.....	50
2.2 Моделирование течи теплоносителя ГЦК.....	57
2.3 Выводы к главе 2	58
Глава 3. Алгоритм определения неисправности измерительных каналов системы акустического контроля течи	60
3.1 Анализ данных тестового воздействия.....	61
3.2 Обоснование алгоритма обнаружения неисправности ИК САКТ	63
3.3 Классификация сигналов тестового воздействия	64
3.4 Формирование диагноза о наличии неисправности	68
3.5 Выводы к главе 3	69
Глава 4. Обнаружение аномалий в работе реакторного оборудования.....	71
4.1 Метод оценки многомерного состояния	73

4.2 Вариационный автоэнкодер.....	80
4.3 Модель обнаружения аномалий.....	84
4.4 Результаты использования разработанного метода для анализа работы ГЦН	87
4.5 Дополнение для ВАЭ	90
4.6 Выводы к главе 4	93
Глава 5. Автоматическая сегментация сигналов электроприводной арматуры сверточной нейронной сетью	95
5.1 Постановка задачи	97
5.2 Подготовка исходных данных.....	97
5.3 Определение временных сегментов для обучение нейронной сети	98
5.4 Описание архитектуры сети	99
5.5 Подбор и анализ функций потерь	100
5.6 Метрика оценки качества нейронной сети.....	103
5.7 Обучение нейронной сети и анализ результатов.....	104
5.8 Выводы к главе 5	107
ОСНОВНЫЕ ВЫВОДЫ И ЗАКЛЮЧЕНИЕ	108
СПИСОК ЛИТЕРАТУРЫ	111

ВВЕДЕНИЕ

Растущая сложность современных промышленных процессов обуславливает возрастающую значимость контроля для обеспечения безопасности производства и качества выпускаемой продукции. Своевременное обнаружение аномальных событий дает возможность принять превентивные меры для предотвращения более серьезных последствий, повысить производительность системы и уменьшить затраты на техническое обслуживание и эксплуатацию. Основная цель обнаружения аномалий или отказов состоит в том, чтобы идентифицировать любое аномальное событие, указывающее на отклонение от поведения процесса по сравнению с его нормальным поведением. Не менее важно произвести диагностику неисправности (или ее локализацию), определяющую первопричину обнаруженной аномалии [1].

Процесс эксплуатации современных АЭС сопровождается регистрацией большого и постоянно растущего числа различных технологических параметров и сигналов системы контроля и систем оперативной диагностики состояния элементов оборудования и результатов неразрушающего контроля [2]. К ним относятся температурные (~3000 шт.), нейтронные (~500 шт.) электрические (~450 шт.), двоичные входные сигналы (~4700 шт.), давления, уровней, расходов и другие (~3200 шт.), которые, в большинстве случаев, передают в Автоматизированную Систему Управления Технологическим Процессом (АСУ ТП) только агрегированную информацию, которая почти никогда не анализируется в последующем.

Столь большой поток информации, приходящийся на оператора, не позволяет ему правильно и своевременно распознать возможную аномалию. О чем может свидетельствовать анализ аварий и инцидентов, произошедших на АЭС [3] – почти все аварии могли быть предотвращены операторами при своевременном обнаружении аномалий.

Вместе с тем, отечественный и зарубежный опыт показывает, что ошибки персонала по-прежнему являются общей причиной аномальных событий в процессе эксплуатации АЭС, доля которых составляет около 55% [4]. Действия персонала в условиях стресса в ходе аварийных ситуаций часто усугубляют ситуацию. Для принятия правильных решений ему необходимо своевременно получать информацию о неисправностях оборудования, когда контролируемые параметры находятся в пределах нормальной эксплуатации, и достаточно времени для принятия взвешенного, обоснованного решения.

Для решения этой проблемы в настоящее время активно разрабатываются системы диагностики, основанные на современных методах интеллектуального анализа данных различного типа. Использование этих методов позволит [2]:

- Оптимизировать процесс принятия решений за счет более рациональной обработки данных, что, в свою очередь, повысит надежность принятия оператором решений;

- Повысить достоверность показаний датчиков за счет диагностирования отказов датчиков, их калибровки и косвенного измерения технологических параметров;

- Снизить информационную нагрузку на персонал за счёт методов понижения размерности, позволяющих использовать более информативную совокупность диагностических признаков;

- Повысить точность математических моделей, описывающих поведение диагностических признаков в режимах нормальной эксплуатации за счет использования преимуществ нейросетевых технологий;

- Увеличить чувствительность алгоритмов обнаружения аномалий за счет перехода к многомерной обработке и учету статистической связи признаков.

Актуальность работы

Эксплуатационные данные информационных систем ядерных энергетических установок (ЯЭУ) и, в частности, атомных электростанций (АЭС) содержат критически важную информацию для обеспечения их безопасности и

надежности, касающуюся процессов, происходящих в установках. Между тем сигналы практически всех измерительных каналов взаимодействуют между собой, и шумовые компоненты могут существенно доминировать над полезной информацией. Анализ аномальных ситуаций на АЭС показал, что раннее обнаружение аномалий может быть достигнуто путем анализа изменений взаимосвязей и характерных признаков в данных эксплуатации. Однако, эта важная информация распределена по большому числу параметров и часто остается незаметной из-за помех и мешающих факторов. Эффективное извлечение и анализ этой информации могут стать ключевым фактором в обеспечении безопасной и надежной эксплуатации ядерных энергетических установок, а также повысить качество их технического обслуживания.

Это обуславливает актуальность развития и совершенствования методов диагностики – формирования и выделения характеристик сигналов (диагностических признаков), содержащих информацию о состоянии оборудования и отдельных элементов технических объектов или особенностях протекания тех или иных процессов в них. При этом классические методы, алгоритмы обработки и представления сигналов многочисленных и различных по природе датчиков должны быть существенно расширены и развиты «в глубину» с целью надежного выявления причинно-следственной связи анализируемых процессов.

В атомной отрасли собран беспрецедентный интеллектуальный потенциал с уникальными знаниями, как в предметной атомной области, так и в области обработки данных. В последней можно выделить два направления: Большие Данные и Машинное Обучение, которые вместе составляют основу интеллектуального анализа данных. Применение интеллектуального анализа данных позволило добиться существенных успехов в различных областях, таких как безопасность сложных промышленных объектов, авиационная и космическая промышленность, а также ряде других отраслей. Методы, используемые в этих направлениях, также применимы в технической диагностике ядерных

энергетических объектов, включающих и АЭС. Эти методы включают в себя алгоритмы обнаружения аномалий, классификации данных, фильтрации шумов и различные архитектуры искусственных нейронных сетей.

Такой подход обеспечивает возможность диагностики даже в условиях ограниченной или отсутствующей априорной информации, а применение позволит своевременно (задолго до выхода измеряемых параметров за эксплуатационные пределы) предоставить эксплуатационному персоналу информацию о возникновении отклонений от режима нормальной эксплуатации или о появлении аномалий в работе оборудования.

Таким образом, разработка методов и алгоритмов диагностирования оборудования и повышения информационной емкости систем контроля оборудования и реакторной установки (РУ) в целом, учитывая потенциальную важность для обеспечения их безопасной и надежной эксплуатации, является актуальной задачей, имеющей практическую ценность.

Степень разработанности темы диссертации

В процессе диссертационного исследования был проведен анализ литературных источников, посвященных применению методов интеллектуального анализа данных для обеспечения безопасности технически сложных промышленных объектов, в том числе и АЭС.

Несмотря на значительное количество публикаций, касающихся применения отдельных методов интеллектуального анализа данных в области атомной энергетики, наблюдается недостаточное разнообразие подходов к решению обозначенных задач, а также заметное отставание во внедрении современных методов анализа данных.

Цели и задачи

Целью работы является реализация новых научно обоснованных технических решений, внедрение которых внесет значительный вклад в развитие страны в сфере разработки, создания алгоритмов для систем диагностирования оборудования АЭС с РУ ВВЭР.

Диссертационная работа направлена на решение научной проблемы – повышение безопасности и надежности эксплуатации действующих АЭС, за счет извлечения и анализа многомерных параметров информации для контроля и диагностики, с использованием современных предиктивных методов анализа данных, что напрямую соответствует пункту 3 паспорта специальности: «П3. Разработка методов расчета технологических процессов в объектах ядерной техники с целью оптимизации их характеристик, повышения надежности оборудования и систем и обеспечения их ядерной и радиационной безопасности».

Для достижения поставленной цели решались следующие задачи:

1. Разработка алгоритма выделения полезного сигнала в измерительных каналах систем акустического контроля течей, основанного на фильтрации глобальных шумов и направленного на повышение надежности определения протечек трубопроводов реакторных установок и повышение чувствительности к течи.

2. Разработка алгоритма определения неисправности измерительных каналов системы акустического контроля течей, основанного на использовании каскада нейросетевых классификаторов и направленного на определение дефектных датчиков и наведенных помех в измерительных каналах.

3. Разработка методов обнаружения аномалий в работе реакторного оборудования, которые основаны на использовании избыточной информации в существующих системах диагностики оборудования и предназначенных для выявления на ранней стадии развития неисправностей, не проявляющихся в эксплуатационных пределах.

4. Разработка алгоритма диагностирования электроприводной арматуры, основанного на применении сверточной нейронной сети для сегментации циклограммы активной мощности и направленного на повышение надежности диагностирования арматуры за счет автоматизации процесса с исключением возможных ошибок, связанных с человеческим фактором.

Научная новизна

Разработан новый алгоритм выделения полезного сигнала в измерительных каналах системы акустического контроля течи (САКТ) в главном циркуляционном контуре (ГЦК), сокрытого в высокоамплитудных посторонних шумах, определяющегося по отношению к общей закономерности поведения во времени множества идентичных каналов, работающих в одинаковых условиях. Алгоритм отличается более высокой надежностью определения протечек трубопроводов РУ за счет сокращения числа ошибок первого рода (ложных срабатываний) и более высокой чувствительностью, позволяя обнаруживать течи с расходом менее установленного концепцией «течь перед разрушением». Кроме того, исследована устойчивость предложенного алгоритма к различным фоновым акустическим выбросам.

Проведен анализ дефектов и встроенной проверки работоспособности измерительных каналов системы акустического контроля течи. На основании данного анализа был предложен и обоснован новый метод проверки работоспособности измерительных каналов САКТ. В основе этого метода лежит разработанный нейросетевой классификатор, отличающийся способностью определять не только дефектные каналы, но и неисправные акустические датчики.

Разработан единый подход к анализу данных оперативного технического контроля для оценки состояния контролируемого оборудования АЭС в процессе эксплуатации. На основании проведенных исследований сформированы модели (нейросетевой вариационный автоэнкодер и многомерный метод оценки состояния) диагностирования оборудования на примере главных циркуляционных насосов (ГЦН). В отличие от имеющихся систем диагностирования, направленных на симптомы аварии или их проявления, предложенный метод позволяет своевременно выявлять аномалию и дает возможность адекватно оценить ситуацию и принять правильное решение. Помимо этого, отличительной особенностью также является возможность определения покомпонентного вклада отдельного параметра в общее отклонение,

что поможет эксперту в анализе первопричины неисправности и в составлении симптомно-ориентированной аварийной инструкции.

Разработан новый подход к использованию сверточной нейронной сети для сегментации временных рядов, представленных сигналами активной мощности ЭПА, для разбиения циклограмм на однородные характерные интервалы времени, из которых извлекаются диагностические признаки. Проведен анализ наиболее подходящих для данной задачи функций потерь, для решения проблемы дисбаланса данных – когда один или несколько классов значительно превышают остальные. Тем самым предложен алгоритм, который, в отличие от имеющихся, позволяет автоматизировать процесс диагностирования ЭПА, значительно увеличить скорость диагностирования и выявления неисправности, а также исключить ошибки, связанные с человеческим фактором. Благодаря автоматизации процесса диагностирования ЭПА стало возможно проводить в онлайн формате.

Теоретическая и практическая значимость

В работе решены практически важные задачи технического диагностирования оборудования АЭС с ВВЭР. Все разработанные решения реализованы в виде алгоритмов и программных продуктов:

– в составе системы акустического контроля течей Нововоронежской АЭС-2 (Энергоблок №1) алгоритм фильтрации глобальных шумов в измерительных каналах систем контроля течей в модуле комплексного анализа течи. Практическая работоспособность алгоритма продемонстрирована на данных, полученных на основе экспериментального обоснования САКТ на специализированном стенде, а также имеющихся данных по протечкам на номинальных параметрах, эксплуатируемых РУ;

– в составе системы акустического контроля течей алгоритм выявления неисправностей измерительных каналов и акустических датчиков, прошедший проверку на реальных данных САКТ Нововоронежской АЭС-2 (Энергоблок №1);

– в составе системы предиктивной аналитики алгоритмы обнаружения аномалий в работе реакторного оборудования. Эффективность разработанных алгоритмов демонстрируется на примере работы главных циркуляционных насосов Нововоронежской АЭС-2 (Энергоблок №1). В процессе исследования были использованы данные различных типов датчиков: вибрационные (виброакселерометры), датчики температуры и давления. На основе этих данных были разработаны критерии диагностирования, которые позволяют выявлять аномалии в работе оборудования и принимать меры по их устранению;

– в составе комплексной системы диагностирования арматуры (КСДА) алгоритм сегментации временных рядов. Для обоснования эффективности алгоритма использовались данные КСДА Нововоронежской АЭС-2 (Энергоблок №1 и №2).

Практическая значимость подтверждается апробацией разработанных алгоритмов в 2021 году в составе специализированного программного обеспечения для систем технической диагностики комплекса системы контроля, управления и диагностики (СКУД) на энергоблоках №1 и №2 НВАЭС-2 с РУ ВВЭР-1200, а также введением их в штатную эксплуатацию (с 2022 года). Помимо этого, комплексное исследование с обработкой сигналов датчиков, а также данных АСУ ТП, проведенное с целью разработки предиктивных методов для диагностирования элементов реакторной установки позволило получить уникальный материал. На основании этого специалистами ООО «Квант программ» был разработан универсальный инструментарий для обработки многоканальных систем контроля независимо от объекта контроля в online и offline режимах для различных прикладных областей при решении задач технического диагностирования.

Методология и методы исследования

Исследования в данной диссертационной работе основаны на современных подходах анализа данных, применяющихся для контроля состояния оборудования. В качестве методологической базы использовались современные

алгоритмы машинного обучения, а также нормативные документы и материалы научных конференций, посвященных вопросам надежности и безопасности технически сложных промышленных объектов.

Положения, выносимые на защиту

1. Обоснование эффективности и устойчивости разработанного алгоритма выделения полезного сигнала в измерительных каналах акустической системы контроля течи. Алгоритм базируется на прогнозировании сигнала заданного измерительного канала, проведенного по регрессионным моделям, построенным по датчикам, находящимися в идентичных условиях.

2. Нейросетевая модель, основанная на классификации неисправностей измерительных каналов, предназначенная для обнаружения неработоспособных акустических датчиков и измерительных каналов.

3. Общий методический подход к разработке алгоритмов распознавания аномальных состояний контролируемого реакторного оборудования по данным систем контроля.

4. Алгоритм автоматической сегментации временных рядов, основанный на сверточной нейронной сети.

Степень достоверности результатов

Достоверность представленных в диссертационной работе основных положений подтверждается результатами экспериментальных исследований, и внедрением алгоритмов в системы диагностирования оборудования АЭС с РУ ВВЭР. Все разработанные методы прошли проверку на экспериментальных данных и в реальных условиях эксплуатации АЭС.

Апробация результатов

Основные положения и результаты диссертационной работы докладывались и обсуждались на научно-технических семинарах кафедры «Ядерные реакторы и установки» МГТУ им Н.Э. Баумана в период 2019-2023 годы, на 8-ой международной молодежной научной конференции «Физика. Технологии. Инновации. (ФТИ – 2021)» (Екатеринбург – 2021), на

научно-технической конференции «Теплофизика реакторов нового поколения (Теплофизика – 2022)» (Обнинск, 2022), на научно-техническом семинаре, проводимом в АО «СНИИП» «Развитие систем диагностирования реакторных установок (РУ)» (Москва – 2022).

Публикации

Материалы диссертации опубликованы в одной монографии (в соавторстве), 6 научных статьях, в рецензируемых ВАК научно-технических журналах, при этом 3 из них переведены на английский язык, опубликованные журналом NUCET Nuclear Energy and Technology (MEPhI National Research Nuclear University) проиндексированном в базе РИНЦ.

Личный вклад автора

Все результаты диссертационного исследования и основные положения, выносимые на защиту, отражают личный вклад автора в опубликованные работы. Подготовка к публикации полученных результатов проводилась совместно с соавторами, причем вклад диссертанта был определяющим. Все представленные результаты получены лично автором.

Структура и объем диссертации

Диссертация состоит из введения, пяти глав, заключения и списка литературы. Общий объем 122 страницы, содержит 33 иллюстрации и 4 таблицы. Список литературы включает 128 наименований.

Благодарности

Автор выражает признательность своему научному консультанту кандидату технических наук В.И. Павелко за ценные методические и практические указания по улучшению ее направленности и содержания, за полезные советы в процессе подготовки и выполнения программы исследований.

Глава 1. Методы предиктивной аналитики для диагностирования РУ

Современные системы диагностирования АЭС генерируют большое количество сигналов и данных. Применение методов интеллектуального анализа данных позволяет максимально использовать доступную информацию для обнаружения неисправностей, определения остаточного срока службы оборудования и решения других важных задач.

Технические средства и системы обеспечивают сбор и хранение данных, поступающих из различных источников [5]. Эти данные содержат информацию о работе практически всего оборудования и ключевых технологических процессах на атомных электростанциях.

Анализ и обработка эксплуатационных данных оборудования позволяют спрогнозировать сроки, в течение которых могут произойти изменение состояния или возникновение аномалий. Это позволяет внедрить стратегию «обслуживания по состоянию», которая приводит к сокращению затрат на техническое обслуживание оборудования, оптимизации сроков и продолжительности планово-предупредительных ремонтов, а также минимизации вмешательств ремонтного персонала в систему, что уменьшает вероятность отказов. Сокращение затрат достигается за счет исключения обслуживания функционирующего оборудования, у которого остаточный ресурс достаточен для работы до следующего запланированного профилактического ремонта [6].

Несмотря на обилие данных, доступных персоналу АЭС, существует дефицит агрегированной диагностической информации, необходимой для оптимизации эксплуатационных и технических процессов. Извлекать полезную диагностическую информацию из данных становится возможным благодаря применению современных математических и статистических инструментов [7]. Они используются для более глубокого понимания процессов, проходящих в оборудовании, обнаружения аномалий и прогнозирования их развития, а также для формирования рекомендаций [8]. Методы, используемые при анализе,

включают в себя: алгоритмы машинного обучения, нейронные сети, распознавание образов, прогнозирование временных рядов, визуализацию, кластерный анализ, многомерные статистические методы, анализ графов, моделирование физических процессов и другие методы интеллектуального анализа данных. Их многообразие, а также применение на АЭС изложено в обзорах [9,10,11]

Полный цикл диагностирования оборудования описан в ГОСТ [12], а его схема показана на рисунке 1.1

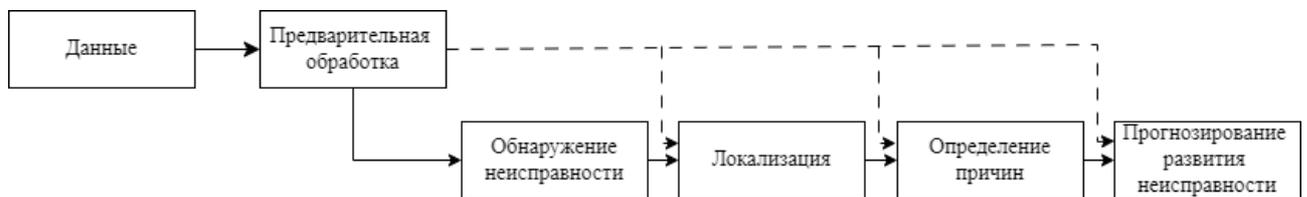


Рисунок 1.1 – Схема цикла диагностирования оборудования

Основной путь цикла диагностирования – последовательное выполнение всех этапов, начиная с «Получения данных», затем «Предварительная обработка», «Обнаружение неисправности», «Локализация», «Определение причин» и, наконец, «Прогнозирование развития неисправностей». Штриховой линией на рисунке 1.1 обозначен дополнительный путь цикла, при котором этапы не вытекают один из другого. Это может происходить при отложенном анализе, когда любой этап рассматривается отдельно от остальных. Также это может происходить при использовании исходных данных в неизменном виде или дополнительных данных на любом этапе. Наконец, это может происходить при использовании других методов предварительной обработки исходных данных для работы алгоритмов.

Стоит уточнить значения некоторых терминов, которые будут использоваться далее. Работа в режиме *оффлайн* (offline) означает работу с историческими данными (архивы), в таком случае для анализа доступна полная выборка данных. Работа в режиме *онлайн* (online) означает анализ в режиме реального времени, в таком случае полная выборка данных недоступна для

анализа. Объекты (векторы) данных могут приходить один за другим в режиме реального времени (streaming data), в таком случае анализ называется *поточечным*, или может быть использован некоторый буфер с привлечением части исторических данных (batch data), и анализ называется *буферным*.

Обучение с учителем представляет собой тип задачи, при котором все режимы работы оборудования известны и классы данных размечены, иначе говоря, есть данные о нормальном режиме и аномальном режиме (желательно обо всех типах аномалий).

Обучение с частичным привлечением учителя представляет собой тип задачи, при котором есть данные только о нормальном режиме работы, то есть метка класса присутствует у части данных, характеризующих нормальный режим работы оборудования.

Обучение без учителя представляет собой тип задачи, при котором данные есть, но не размечены: отсутствует метка класса для всех данных.

1.1 Предварительная обработка данных

Собираемые средствами измерений сигналы относятся к сырым (необработанным) данным. Одна из проблем при анализе данных связана с асинхронностью генерации и поступления информации. Неисправность каналов измерений приводит к пропускам в данных, появлению недостоверных показаний и зашумлению сигналов. При этом, системы самоконтроля или самодиагностирования измерительного оборудования могут как обнаруживать недостоверные значения, так и пропускать их. Применение различных методов предварительной обработки данных позволяет минимизировать влияние подобных факторов на качество диагностирования объекта.

Несмотря на наличие в данных информации о зарождающихся неисправностях, использование так называемых сырых данных в аналитических алгоритмах крайне затруднено. Алгоритмы обнаружения неисправностей,

распознавания образов, локализации неисправностей, прогнозирования их развития и другие, для своей качественной работы требуют предварительной обработки сигналов. В качестве методов предварительной обработки используются как методы машинного обучения [13], так и классические методы обработки сигналов [8,14]. В современных отечественных системах диагностирования оборудования АЭС используются следующие методы предварительной обработки: спектральный анализ, фильтрация, скользящее среднее, генерация из существующих сигналов диагностических признаков (предикторов) и другие. Многие из них описаны в работах [5,15].

Этап предварительной обработки может способствовать сокращению объема анализируемых данных, выделению дополнительных информативных диагностических признаков, нахождению сложных зависимостей и скрытых закономерностей, отбрасыванию неинформативных исходных сигналов, удалению шумов и так далее, что, помимо прочего, может приводить к улучшению качества работы алгоритмов обнаружения, локализации, прогнозирования и других аспектов анализа измерительной информации.



Рисунок 1.2 – Классификация методов предварительной обработки данных

Необходимость и важность этапа предварительной обработки обусловлена обеспечением устойчивости алгоритмов обнаружения и подтверждается наличием этого этапа в подавляющем большинстве упомянутых в текущем обзоре работ, а также включением методов предварительной обработки во многие обзоры методов интеллектуальной обработки данных [10,11]. Обобщенная

классификация методов предварительной обработки данных, основанная на анализе различных работ, приведена на рисунке 1.2.

В общем случае этап предварительной обработки состоит из трех основных частей [16]:

- очистка данных;
- преобразование признаков;
- отбор и создание диагностических признаков.

Этап очистки позволяет бороться с недостоверными значениями и выбросами за счет их удаления или корректировки. Также на данном этапе происходит заполнение пропусков или удаление объектов данных с пропусками, если их доля мала. Данные, имеющие большое число пропусков или недостоверных значений, также могут исключаться из дальнейшего анализа.

Все измерения, влияющие на безопасность АЭС, оперативно диагностируются и сопровождаются индикатором достоверности, показывающим степень надежности информации, что позволяет избавиться от недостоверных данных в АСУ ТП. Однако не все измерения оснащаются надежными алгоритмами самоконтроля. В мире существует большое число работ [5,17,18,19,20], направленных на решение проблемы поверки измерительного оборудования для обеспечения контроля достоверности измерений.

Пропуски в данных появляются ввиду несовершенства современных измерительных систем, каналов связи и другой инфраструктуры, что является проблемой при работе с методами обнаружения аномалий. Простейшими подходами являются игнорирование данных с пропусками и замена пропусков специальными значениями. Также пропуски могут быть заполнены стандартными методами, например, скользящим средним или медианой по выбранному окну, средним (количественный признак), модой (категориальный признак) или медианным значением по всему временному ряду, последним значением, полученным перед пропуском, и др. Однако пропуски могут быть заполнены и продвинутыми методами, например, методами машинного обучения: (регрессия

[21], метод ближайших соседей [22], нейронные сети [23], метод k -средних и нечетких k -средних [24] и др.), методом сингулярного разложения и др. В работе [25] представлено сравнение разных методов заполнения пропусков, а в работе [26] представлены обзоры методов заполнения пропусков.

Для борьбы с аномальными значениями (выбросами) используются как классические методы, например, удаление значений, не соответствующих физическим законам или превышающих стандартное отклонение признака, так и современные методы интеллектуального анализа данных и машинного обучения. Однако в большинстве случаев задача поиска аномалий в данных является задачей обучения без учителя, поэтому для ее решения применим класс методов машинного обучения, обучающихся без учителя. Обзор классов моделей обнаружения выбросов и аномалий представлен в [27]. В работе выделяются шесть основных подходов, каждому из которых соответствует класс моделей:

1. поиск экстремальных значений в данных;
2. кластеризация;
3. модели, основанные на расстоянии;
4. модели, основанные на плотности точек;
5. вероятностная кластеризация;
6. информационно-теоретические модели.

Отдельным подходом к решению задачи поиска выбросов является использование ансамблей моделей [28,29]. Ансамбли основаны на последовательном или параллельном применении базового алгоритма или набора алгоритмов к подвыборкам данных или подпространствам признаков и дальнейшем оценивании полученных наборов ответов. На построении ансамблей основаны градиентный бустинг, случайный лес, бэггинг и другие модели.

На этапе преобразования признаков изменяются их значения (нормировка, изменение частоты дискретизации), меняется их тип (категоризация дискретных и непрерывных значений), модальность (видео переводятся в последовательность картинок, картинки в таблицы числовых данных) и т.д.

Большинству алгоритмов, используемых для предварительной обработки, требуются на вход данные, признаки которых находятся в одном масштабе, так как дисперсия признаков сказывается на их значимости для алгоритмов [13]. Существует большое число способов нормировки, наиболее распространенные из них [30]:

Линейные:

- нормализация (стандартизация): приведение к нулю среднего, дисперсии к единице;
- min-max нормализация (нормировка на отрезок): масштабирование признаков на интервал между нулем и единицей. Ноль соответствует минимальному значению до нормализации, а единица – максимальному;
- decimal scaling normalization: находится количество цифр i максимального значения временного ряда, далее каждое значение ряда делится на 10^i ;
- нормировка по максимуму: каждое значение временного ряда нормируется на максимум всего ряда.

Нелинейные:

- гиперболический тангенс: приводит значения к интервалу $[-1; 1]$;
- логистическая функция (сигмоида): приводит значения к интервалу $[0; 1]$.

Кроме нормировки к признакам часто применяют преобразование Бокса-Кокса (логарифмирование) [31], чтобы сделать распределение признаков похожим на нормальное. Преобразование может применяться многократно, но, стоит отметить, что логарифмирование может применяться только к положительным значениям.

Еще одной важной задачей является приведение сигналов с разной частотой дискретизации к единой. В работе [5] описаны основные подходы:

- уменьшение частоты дискретизации всех процессов до минимальной;
- увеличение частоты дискретизации всех процессов до максимальной;

- приведение к промежуточной или любой другой частоте дискретизации.

Выбор конкретной частоты, к которой нужно привести все сигналы, должен основываться на характерной частоте протекания анализируемого процесса и быть согласованным с последующими этапами диагностирования. Значительное уменьшение частоты может привести к потере информации в сигналах (теорема Котельникова), с другой стороны, необоснованное увеличение частоты может сказаться на вычислительной сложности последующих процессов анализа данных.

В [5] описаны условия применимости, достоинства и недостатки подходов, но только в рамках спектрального анализа. Стоит дополнить главу монографии несколькими моментами:

1. Так как методы машинного обучения набирают свою популярность, в том числе из-за возможности работать с большими данными (Big data), иногда стоит приводить сигналы к низкой частоте для сокращения суммарной вычислительной сложности задачи. Также возникает необходимость уменьшать частоту дискретизации для решения задач в режиме реального времени, если набор последовательно применяемых методов слишком велик.

2. В упомянутой работе также упущен важный момент применения вышеуказанных подходов в режиме реального времени. Так как в режиме реального времени (при поточечном анализе) интерполирование не применимо, а экстраполирование является отдельной сложной задачей и практически не используется, приведение к единой частоте дискретизации может быть реализовано с использованием более простых методов:

- увеличение частоты дискретизации. Заполнение текущего интервала последним полученным значением с последующей дискретизацией;
- увеличение частоты дискретизации. Заполнение средним или медианным значением на последнем интервале с последующей дискретизацией;
- уменьшение частоты дискретизации. Выбор экстремумов, среднего или медианного значения на интервале.

Под отбором признаков понимается уменьшение количества признаков, например, за счет поиска подпространства меньшей размерности с помощью методов понижения размерности или за счет простого отбрасывания части неинформативных признаков. Отбор признаков используется для упрощения моделей, сокращения сложности задачи обучения моделей, избегания «проклятия» размерности (экспоненциальный рост необходимых экспериментальных данных в зависимости от размерности пространства) и так далее. Задача выбора системы информативных признаков с полным многообразием используемых методов рассмотрена в [13,26]. Согласно этим работам, наиболее распространенными алгоритмами являются следующие:

- полный перебор всевозможных наборов признаков;
- последовательное добавление признаков (Add);
- последовательное удаление признаков (Del);
- генетический алгоритм;
- случайный поиск;
- кластеризация признаков.

Для задач машинного обучения часто используется регуляризация, накладывающая штраф за сложность модели [13]. L1-регуляризация (LASSO) [32] решает в том числе задачу отбора признаков, исключая часть исходных неинформативных признаков из подвыборки, используемой для обучения и работы модели.

Создание новых признаков возможно на основе логики и физики процесса или на основе стандартных преобразований – возведение в степени полинома или произведение значений признаков. Созданием новых диагностических признаков является также получение автохарактеристик сигналов с помощью скользящего буфера и всевозможных корреляционных пар и прочие достаточно тривиальные преобразования, которые применительно к АЭС представлены в монографиях [5,15,33].

Большинство методов понижения размерности решают и задачу сокращения количества признаков, и задачу создания новых диагностических признаков. Методы понижения размерности проецируют данные в пространство меньшей размерности, в отличие от методов отбора учитывается вся исходная информация, что позволяет упростить и улучшить процедуру контроля технического состояния и поиска аномалий в сигналах. Задача снижения размерности имеет множество применений, описание которых представлено в работе [8]. Примером использования методов понижения размерности является визуализация: представление набора данных в двухмерном или трехмерном пространстве.

К основным методам понижения размерности, применяемым для диагностирования оборудования АЭС можно отнести следующие:

– *метод главных компонент* [18,19,20]: заключается в поиске в исходном пространстве гиперплоскости заданной размерности с последующим проецированием данных на найденную гиперплоскость. Оси нового пространства являются линейной комбинацией исходных и выбираются, исходя из величины дисперсии исходных признаков. Преобразование пространства измерений в новое ортогональное пространство выполняется приведением матрицы ковариаций (корреляций) к диагональному виду, поэтому исходные признаки в новом пространстве некоррелированы;

– *метод независимых компонент* [34,35]: в отличие от метода главных компонент находит пространство, в котором исходные признаки являются не только некоррелированными, но и независимыми по статистическим моментам более высокого порядка, иначе говоря, метод независимых компонент решает задачу поиска любого, в том числе неортогонального, пространства, оси которого являются линейной комбинацией исходных;

– *метод частично наименьших квадратов* [8,10,36]: выбирает оси нового пространства, исходя из максимизации ковариации между матрицей признаков и матрицей ответов, причем новые пространства находятся для обеих матриц.

Новые оси для пространства признаков вычисляются так, чтобы обеспечить максимальную дисперсию по осям в новом пространстве для матрицы ответов. Используя в качестве ответов данные о неисправностях, мы получаем для матрицы признаков пространство меньшей размерности, позволяющее точнее определять различные неисправности;

– *линейный дискриминантный анализ* [8]: заключается в поиске линейной комбинации признаков, позволяющей разделить события из разных классов (определяющих разные неисправности) наилучшим образом. Используется для задач классификации и понижения размерности исходного признакового пространства;

– *канонический корреляционный анализ* [8,37]: это метод поиска пространств меньшей размерности для двух наборов переменных (признаки и ответы) при проецировании данных, в которые взаимные корреляции между этими двумя наборами переменных максимальны среди всех возможных вариантов пространств. Базис переменных в новом пространстве является линейной комбинацией исходных переменных. Канонический корреляционный анализ применяется в качестве метода снижения размерности, но может использоваться для задачи отбора информативных признаков [38];

– *факторный анализ* [39,40]: в его основе лежит предположение, что известные переменные зависят от меньшего количества неизвестных переменных и случайной ошибки. Это позволяет использовать факторный анализ для замены коррелирующих измерений меньшим числом новых переменных (факторов), причем утеряно может быть минимальное количество информации, содержащейся в исходных данных.

Также к методам предварительной обработки относится создание диагностических признаков – индикаторов работоспособности. Индикаторами работоспособности являются диагностические признаки, характеризующие состояние системы, созданные экспертом на основе опыта для наглядного и

эффективного понимания состояния технической системы и, соответственно, для обнаружения аномалий в работах [5,41].

Диагностическими признаками можно назвать и главные компоненты в методе главных компонент, и признаки из бутылочного горлышка автокодировщика, и спектр Фурье сигнала, однако основное отличие индикаторов работоспособности состоит в том, что их создание является полностью эвристическим методом. Создание индикаторов работоспособности основано на обработке и формализации экспертом системы закономерностей, которые не описываются существующими физическими и математическими моделями оборудования.

В качестве преимуществ индикаторов работоспособности можно выделить возможность создания рационального решения, аккумулирующего опыт экспертов, а также простоту реализации индикаторов. Недостатками же являются отсутствие в основе метода физических либо математических моделей и его ограниченность: как правило, на основе одного такого коэффициента выявляют неисправности одного рода для единицы оборудования.

Каждый метод предварительной обработки имеет свою специфику в отношении исходных данных: некоторые способны работать с одним объектом данных, другие требуют вычисления величин на основе тренировочной выборки или буфера. Кроме того, предварительная обработка при работе в режиме реального времени должна соответствовать проведенной при обучении модели диагностики, иначе модели могут показывать неверные результаты. Для этих случаев стоит оговорить механизмы применения методов предварительной обработки:

– поточечное преобразование при обучении и работе. Этот механизм применяется, когда используемым методам предварительной обработки требуется вектор состояния только в текущий момент времени. Примеры таких преобразований: удаление данных, превышающих некоторый порог (например,

физически обоснованный), возведение признака в степени полинома, произведение значений признаков и другие;

– полное или буферное преобразование при обучении, поточечное при работе. Этот механизм применяется, когда преобразованию требуется вычисление величин, например, среднего или дисперсии на обучающей выборке. Полученные на этапе обучения величины сохраняются в памяти и используются при работе в режиме реального времени для каждого вновь пришедшего вектора состояния.

Примеры таких преобразований: одноклассовый метод опорных векторов, изолирующий лес, минимальный определитель матрицы ковариации, все указанные в работе линейные методы приведения признаков к единому масштабу, метод главных компонент и другие;

– буферное преобразование. В данном случае подразумевается преобразование признаков, основанное на вычислении характеристик с помощью скользящего окна или скользящего буфера. Примером является вычисление скользящего среднего сигнала за окно или получение автохарактеристик сигналов с помощью скользящего буфера и всевозможных корреляционных пар.

Примером использования методов предварительной обработки применительно к АЭС можно назвать кластеризацию сигналов системы обнаружения свободных/слабозакрепленных предметов (СОСП) [42]. Раннее обнаружение этих предметов позволяет минимизировать повреждения и повысить уровень безопасности эксплуатации АЭС. Соударение свободного предмета всегда характеризуется наличием случайного (стохастического) компонента в сигнале датчика. Выявление стохастического и детерминированного компонентов сигнала возможно только статистическим путем. Регистрация кратных событий (последовательных во времени событий со схожими характеристиками), вероятнее всего, обусловлена технологическими причинами. Таким образом, если классифицировать кратные события, которые имеют технологическую природу, можно будет их отделить от сигналов порожденных

свободных/слабозакрепленных предметов, так как вероятность того, что характеристики таких сигналов будут схожи, стремится к нулю.

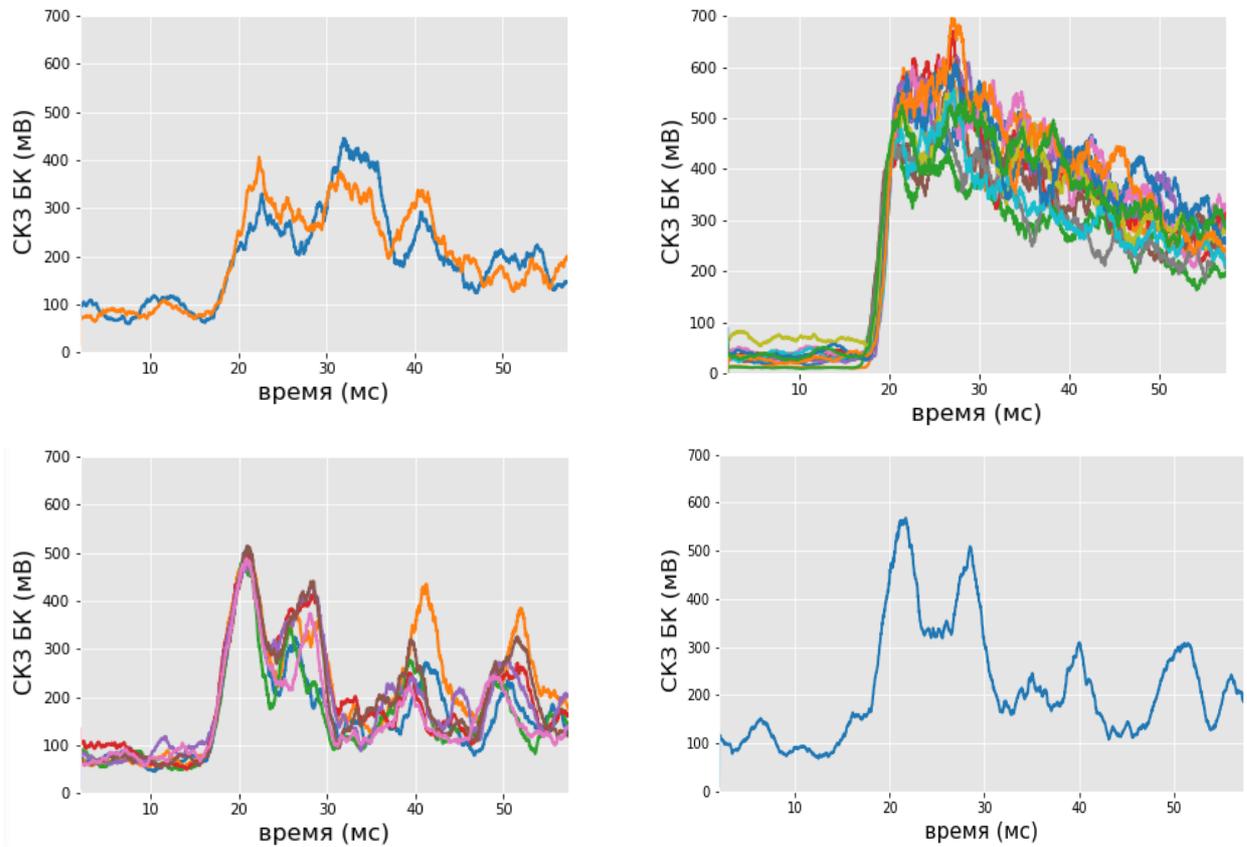


Рисунок 1.3 – Результат кластеризации СКЗ сигналов СОСП

На рисунке 1.3 приведен пример кластеризации среднеквадратичных значений (СКЗ) сигналов СОСП. Кластер, содержащий только один сигнал, потенциально является сигналом порожденным свободным/слабозакрепленным предметом.

1.2 Обнаружение неисправностей

Задача выявления неисправностей является подмножеством более широкой задачи обнаружения аномалий в данных [43].

В области обнаружения неисправностей выделяется три основных методологических подхода:

- модельный подход, основанный на физической модели оборудования;
- безмодельный подход, не использующий физическую модель;
- гибридный подход, сочетающий элементы обоих предыдущих методов.

Физическая модель представляет собой математическое описание объекта диагностирования, основанное на уравнениях, которые отражают физические законы, управляющие процессами в системе. Физическое моделирование считается оптимальным подходом для задач диагностирования благодаря высокой точности и способности предоставлять интерпретируемые результаты. Однако его применение ограничивается сложностью разработки адекватных моделей оборудования, точно отражающих поведение оборудования, что требует значительных ресурсов и экспертизы.

Обнаружение неисправностей без использования физической модели предполагает применение следующих подходов:

- статистические методы (критерии) обнаружения, основанные на проверке гипотез;
- обнаружение аномалий, основанное на статистическом моделировании;
- критерии обнаружения, основанные на экспертных знаниях.

Эти методы позволяют выявлять неисправности на основе анализа данных и опыта экспертов, без необходимости использования детальных физических моделей системы.

Гибридные модели разрабатываются для того, чтобы объединить преимущества описанных выше подходов. Процесс их создания включает в себя моделирование основных компонентов системы, а затем уточнение модели с помощью инструментов интеллектуального анализа данных, таких как методы машинного обучения.

Одним из наиболее широко используемых методов выявления неисправностей с помощью физических и гибридных моделей является сопоставление выходных параметров модели и объекта диагностики (разладок) и последующий их анализ.

Статистические критерии обнаружения аномалий [44] опираются на проверку статистических гипотез. При заданном уровне достоверности определяются контрольные границы (на основе данных репрезентативной выборки), превышение которых указывает на отклонение значений в анализируемом периоде от нормального режима работы и, следовательно, может свидетельствовать о наличии в данных аномалии [45].

Проверка статистических гипотез представляет собой фундаментальный методологический инструментарий математической статистики для комплексного аналитического исследования. Ключевой особенностью данного подхода является возможность формулировки и тестирования предположений о стохастических характеристиках исследуемых процессов через применение специализированных статистических методов. Методологический инструментарий позволяет подтверждать или опровергать гипотезы о свойствах сигнала, а гипотезы, в свою очередь, могут формулироваться относительно различных его характеристик. Например, можно выдвигать предположение о постоянстве его среднего значения на всем интервале нормальной работы объекта диагностирования [46]. В рамках данного подхода были разработаны такие методы, как критерий Неймана-Пирсона и теория последовательного обнаружения Вальда [47]. Особую значимость эти методы приобрели в области диагностики оборудования ядерной энергетики, демонстрируя высокую эффективность при решении сложных технических задач [48,49].

Статистические критерии подразделяются на два принципиальных класса: одномерные и многомерные модели, каждая из которых имеет специфические характеристики и области применения. Одномерный статистический анализ характеризуется исследованием изолированного временного ряда без учета взаимосвязи с другими параметрами. Данный подход преимущественно применяется для обнаружения аномалий через предварительно полученные диагностические признаки.

Многомерный статистический анализ представляет более сложную методологию, которая учитывает комплексное взаимодействие между сигналами. Математический аппарат этого подхода позволяет не только фиксировать наличие неисправности, но и выявлять скрытые взаимосвязи и закономерности, а также устанавливать причинно-следственную связь между различными параметрами технической системы, что обеспечивает более глубокое понимание процессов, проходящих в диагностируемом объекте, и повышает точность прогнозирования потенциальных проблем.

Целью статистического контроля процесса является мониторинг процесса для выявления аномального поведения. Основным инструментом статистического контроля являются контрольные карты (диаграммы), позволяющие отслеживать динамику процесса в реальном времени [50].

Методология статистического контроля основывается на разделении состояний объекта на контролируемое и неконтролируемое. Контролируемый режим, в отличие от неконтролируемого, характеризуется стабильностью параметров и отсутствием значимых отклонений. Таким образом, анализ контрольных карт сводится к непрерывному сравнению фактических значений параметров с заранее определенными пороговыми значениями, превышение которых свидетельствует о потенциальной дисфункции системы и необходимости оперативного вмешательства.

К основным диаграммам можно отнести следующие:

– Контрольные карты Шухарта – графический метод статистического контроля, позволяющий оценивать динамику среднего значения технологического процесса. Визуализация сопровождается заданием верхних и нижних границ, выход за которые сигнализирует о фиксации неисправности. Для предотвращения ложных срабатываний применяется специальный алгоритм, предусматривающий последовательное превышение контрольных границ [51].

– Кумулятивная сумма – заключается в последовательном накоплении отклонений относительно усредненного значения исследуемого параметра. Метод

предполагает накопление k предыдущих значений, на основе которых формируется суммарная оценка текущего состояния системы. В отличие от контрольных карт Шухарта, регистрирующих лишь существенные отклонения, кумулятивная сумма обеспечивает опережающее обнаружение малейших изменений [52].

– Экспоненциально взвешенное скользящее среднее – статистический метод фильтрации и обработки данных, который позволяет проводить динамическую оценку временных рядов с учетом временной памяти [53]. Модель описывается функцией принятия решения, объединяющей текущие данные с предыдущим средним значением, и записывается рекуррентной формулой:

$$z_i(t) = \lambda x_i(t) + (1 - \lambda)z_i(t - 1) \quad (1.1)$$

где x_i – i -е значение контролируемой переменной в момент времени t , а λ – коэффициент затухания, принимающий значения от 0 до 1, и определяющий временную память функции принятия решений. При малых значениях λ существенней вклад прошлых значений, а при больших – текущих.

Расчет контрольных пределов осуществляется через формулу:

$$UCL, LCL = \mu_0 \pm L\sigma_0 \sqrt{\frac{\lambda}{2 - \lambda}} \quad (1.2)$$

где L – параметр чувствительности обнаружения, который устанавливается с учетом вероятности ложных срабатываний, а μ_0 и σ_0 – среднее и стандартное отклонения данных без аномалий.

Представленные контрольные карты являются одномерными инструментами статистического контроля и их применимость основывается на предположении, что данные процесса не коррелированы. Такое предположение может быть неверным в процессах на АЭС. Тогда можно рассмотреть два варианта. Первый заключается в использовании моделирования временных рядов, т.е. для моделирования переменных и использования остатков, полученных в результате этого моделирования временных рядов, которые являются предположительно некоррелированными, для мониторинга процесса с помощью

обычных диаграмм контроля. Вторым вариантом заключается в использовании многомерного статистического инструмента управления процессом, такого как метод главных компонент.

Но процессы функционирования оборудования АЭС обычно нелинейны и динамичны. Также некоторые переменные процесса могут влиять на другие переменные с временной задержкой [54]. Переменная процесса с задержкой по времени может иметь более сильную связь с другими переменными (с задержкой или без), чем переменная без задержки. Таким образом, возможна высокая взаимная корреляция между переменными процесса с различными временными задержками, и трудно выбрать вместе автокорреляцию и взаимную корреляцию, т. е. динамические признаки, для каждой переменной процесса. Однако ожидается, что правильный выбор улучшит поведение схемы контроля технического состояния.

Для решения данных проблем разработано большое число модификаций и дополнений стандартных методов:

- «ядерные» (kernel) методы: в отличие от линейных методов понижения размерности, нелинейные позволяют снижать размерность наиболее эффективно благодаря использованию нелинейной комбинации признаков для создания нового пространства меньшей размерности;

- динамические (dynamic) методы: динамические методы, используемые для анализа переходных процессов, дополняют исследуемую выборку заданным количеством предыдущих наблюдений и учитывают автокорреляции и взаимные корреляции со смещениями во времени;

- вероятностные (probabilistic) методы: вероятностные методы моделируют распределение данных как многомерное гауссовское.

Однако, современные задачи технической диагностики оборудования АЭС характеризуются высокой степенью неопределенности информационного пространства. Значительная часть диагностической информации представлена словесными описаниями, экспертными заключениями и приблизительными

оценками, что существенно усложняет процесс формализации задачи и математического анализа.

Теория нечетких множеств выступает эффективным инструментом формального представления и компьютерной обработки неоднозначной информации [55]. Алгоритмы нечеткой логики успешно применяются для обнаружения аномалий в работе оборудования АЭС [56], позволяя прорабатывать информацию, которая не подвергается непосредственному измерению, а также служат методологической базой при создании экспертных систем диагностирования [2,57,58].

Ключевое преимущество подхода состоит в способности моделировать сложные системы без жестких математических ограничений. Алгоритмы имеют малую чувствительность к небольшим отклонениям и позволяют интегрировать экспертные знания и количественные параметры, обеспечивая более глубокий анализ оборудования

Еще одним критерием обнаружения на основе экспертных знаний является режимная диагностика (деревья решений) – метод, позволяющий осуществлять комплексный анализ причинно-следственных взаимосвязей нежелательных событий [5], который основывается на дедуктивном подходе и логической последовательности исследования потенциальных факторов, влияющих на возникновение конкретных аномалий. К таким факторам могут относиться отказы элементов оборудования, превышения пороговых значений и другие события, потенциально приводящие к дисфункциям системы.

Диагностическая процедура предполагает последовательный переход между узлами дерева решений в зависимости от развития аномального события и результатов текущих измерений. Принципиальная особенность метода заключается в возможности как прямого, так и обратного трассирования причинно-следственных связей.

Основными преимуществами метода можно назвать высокую интерпретируемость и возможность получения конкретных диагностических

заклучений. Метод отличается строгостью, систематичностью и гибкостью, что позволяет эффективно исследовать многофакторные взаимодействия в технических системах.

Характерным примером, демонстрирующим описанные подходы, является алгоритм раннего обнаружения аномалий главных циркуляционных насосов (ГЦН) ВВЭР-1000 по данным технологического контроля [41]. Диагностическая стратегия в поставленной задаче обусловлена следующими функциональными особенностями работы ГЦН АЭС: специфика функционирования реакторной установки ВВЭР-1000 характеризуется наличием четырех параллельно работающих контуров с идентичными условиями эксплуатации, а вероятность одновременного выхода из строя нескольких насосов существенно ниже риска отказа одного агрегата.

По описанной в [41] методике выделялись информативные параметры, изменение совокупности которых во времени представлялось характеристическим параметром H_{ik} .

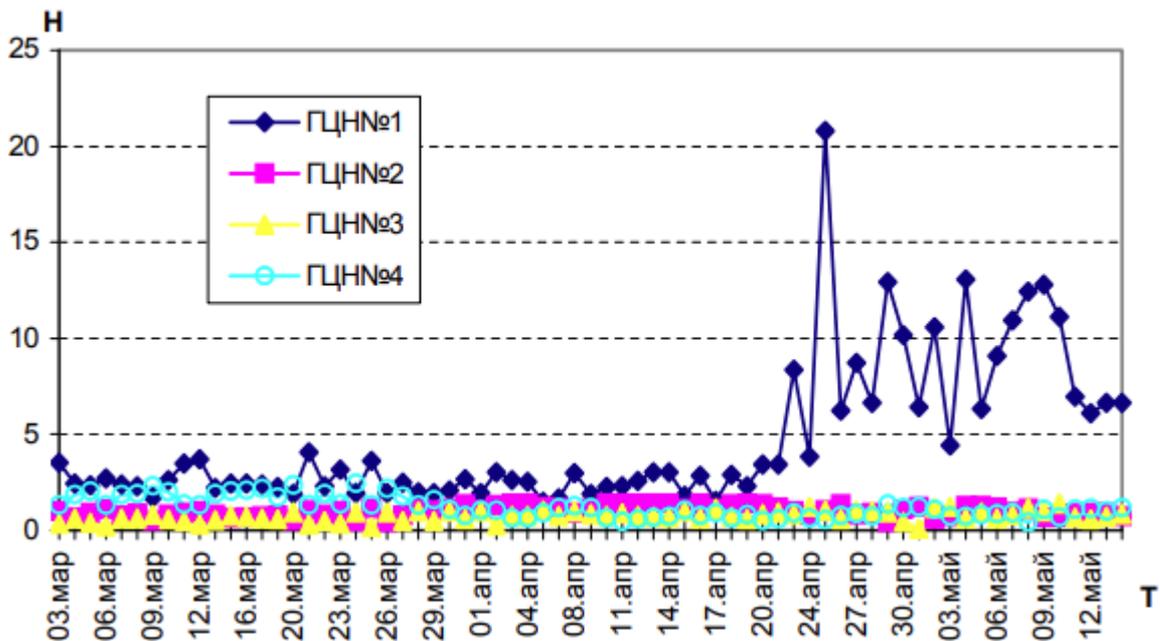


Рисунок 1.4 – Изменения состояния ГЦН НВАЭС блока 5

Анализ рисунка 1.4 указывает на принципиальное отличие в поведении ГЦН 1, который за месяц до нештатной ситуации демонстрирует существенное отклонение с резкой сменой режимов.

Таким образом, использование методов обнаружения неисправностей, при постоянном контроле состояния оборудования с использованием всех измеряемых параметров, позволит определять аномалии на ранней стадии.

1.3 Прогнозирование технического состояния

Современные методы прогнозирования представляют собой комплексный инструментарий диагностики технических систем, который традиционно подразделяется на методы, основанные на данных и модельно-ориентированные (методы, основанные на моделях) подходы [59,60].

Модельно-ориентированные методы основываются на знаниях о системе и математическом моделировании процессов. Они предполагают применение как имитационного физического моделирования [61], так и статистических процедур оценки состояния, среди которых наиболее распространены калмановская фильтрация [62] и фильтры частот [63]. Ключевым преимуществом такого подхода является возможность глубокого понимания внутренних механизмов функционирования системы, однако их надежность существенно снижается при усложнении системы, когда построение точной математической модели становится невозможным и требуется значительная формализация.

Методы, основанные на данных, принципиально отличаются использованием исключительно эмпирической информации для построения прогнозных алгоритмов. Они трактуют технический объект как "черный ящик", фокусируясь на статистических закономерностях поведения системы, что требует обширной обучающей выборки, тем самым усложняя процесс прогнозирования. Комбинирование описанных методов обеспечивает значительное улучшение прогнозных моделей за счет компенсации ограничений каждого из них.

Математическое моделирование в модельно-ориентированном методе выступает ключевым инструментом для достижения глубокого физического понимания системы. Оно обеспечивает всестороннее описание поведения технического объекта, охватывая как штатные, так и нештатные режимы эксплуатации. Принципиальным механизмом прогнозирования является оценка разладок - отклонений между фактическими измерениями и прогнозируемыми параметрами модели. В идеальной ситуации разладки стремятся к нулю, однако реальные условия эксплуатации обуславливают наличие шумов и погрешностей моделирования. Разладки выступают количественным индикатором изменения в системе: низкие значения характеризуют штатный режим, высокие – свидетельствуют о потенциальной неисправности в системе. Статистическая интерпретация разладок позволяет оценивать вероятность безотказной работы и прогнозировать потенциальные отказы.

Ключевое достоинство данных методов заключается во встраивании физических закономерностей в логику диагностирования. Взаимосвязь отказов компонентов позволяет динамически адаптировать модель. Накопление новой информации дает возможность корректировать модель, повышая точность прогнозирования технического состояния системы. Такая динамическая природа моделирования обеспечивает высокую прогностическую способность.

Прогнозирование параметров технических систем представляет собой метод, который особенно актуален при невозможности построения прямой физической модели процесса. Ключевым элементом этого метода является редукция сложной системы для оценки неизвестного вектора параметров модели. Такой подход позволяет преобразовать сложные системные взаимодействия в формализованную математическую модель на базе анализа входных и выходных последовательностей [64].

Несмотря на потенциальную эффективность модельно-ориентированных методов в задачах диагностирования состояния оборудования, практика часто ограничивается анализом доступных временных реализаций контролируемых

сигналов. За невозможностью построения адекватной математической модели процесса, алгоритмы прогнозирования обращаются к эмпирическим методам, использующим статистический анализ временных рядов с возможностью построения нелинейных структур, способных обеспечить желаемые результаты с учетом входных данных. В отличие от модельно-ориентированного подхода, эти методы демонстрируют высокую универсальность и применимость для широкого спектра систем. Вместе с тем, данный подход имеет определенные ограничения, среди которых критическим является потребность в значительных массивах эмпирических данных для корректного обучения и верификации моделей. Очень важным шагом в алгоритме, основанном на данных, является выбор данных для контроля технического состояния, которые имеют отношение к работоспособности системы. Методы, основанные на данных, строятся на предположении, что полученные статистические данные остаются почти неизменными во время номинального поведения системы, а это означает, что большие изменения в статистике связаны только с аномалиями (неисправностями) в системе.

В отличие от обычных методологий технического обслуживания, методы прогнозирования, основанные на знаниях модели или доступных измерениях, позволяют прогнозировать состояние системы и оценивать скорость ее деградации на основе наблюдаемого состояния, что в свою очередь позволяет переходить к более предпочтительной стратегии обслуживания по состоянию.

Концептуальный подход к прогнозированию предполагает использование двух типов моделей: регрессионных и авторегрессионных.

Регрессионное прогнозирование охватывает широкий спектр методов, среди которых особое место занимают [7,65]:

- линейная регрессия и ее нелинейная (ядерная) вариация;
- метод опорных векторов, демонстрирующий высокую эффективность при работе с многомерными пространствами;

– стохастические алгоритмы, такие как случайные леса и градиентный бустинг, позволяют осуществлять прогнозирование через ансамблевое моделирование;

– нейронные сети – гибкий инструмент, способный улавливать сложные нелинейные зависимости.

Авторегрессионные модели базируются на анализе временных рядов и внутренних закономерностей. Среди них выделяются:

– ARIMA-модели, позволяющие осуществлять комплексный анализ динамических процессов через комбинацию авторегрессионных и скользящих компонентов [66].

– Векторные авторегрессионные модели, обеспечивающие одновременное прогнозирование нескольких взаимосвязанных параметров [67].

– Модель Хольта-Винтерса, реализующая мощный механизм тройного экспоненциального сглаживания с учетом трендовых и сезонных компонентов [67].

– LSTM-сети – продвинутая технология прогнозирования, способная накапливать и анализировать долгосрочные зависимости [68].

Представленные модели характеризуются высокой вычислительной сложностью и требуют значительных вычислительных ресурсов. К их достоинствам можно отнести высокую точность прогнозирования, интерпретируемость результатов и способность выявлять сложные взаимосвязи в анализируемых данных.

1.4 Нейронные сети

Одним из основных направлений машинного обучения являются нейронные сети, которые лежат в основе искусственного интеллекта. Нейронные сети самостоятельно извлекают знания из примеров в процессе их обучения.

Простейший элемент нейронной сети – нейрон – элементарный вычислительный модуль, который может иметь несколько входов и один выход. При соединении выхода одного нейрона со входом другого нейрона накладывается вес, который называется синапсом. В процессе обучения синапсы изменяются (настраиваются), придавая больший (меньший) вес выходу того или иного нейрона. Из нейронов состоят слои, множество которых образуют нейронную сеть. Различают три основных типа слоев: входной, скрытый и выходной. В нейроне скрытого слоя производится суммирование взвешенных выходов предыдущего слоя нейронов, в результате чего получается линейная комбинация сигналов предыдущего слоя. Далее на эту линейную комбинацию воздействуют функцией активации и получается выходной сигнал данного нейрона. Разработан целый класс функций активаций, назначение которых – не пропускать незначимую информацию к следующему слою нейронов и, напротив, усиливать значимую. Функции активации – монотонно возрастающие, а наиболее распространённой является сигмоидная функция активации, которая дифференцируема в каждой точке и в пределе ($a \rightarrow \infty$) стремится к ступенчатой функции:

$$g(x, a) = \frac{1}{1 + e^{-ax}} \quad (1.3)$$

Простейшая нейронная сеть состоит всего из одного нейрона, у которого несколько входов и всего один выход. Его называют персептроном. Он совершает последовательность объявленных выше вычислений: линейная комбинация входов и воздействие функцией активации. Несмотря на простоту персептрона, он справляется с некоторым классом прогнозных задач. Далее, по мере увеличения сложности идут однослойные нейронные сети. Они обладают несколькими выходами, что расширяет возможности классификации.

Объединение нескольких персептронов в слои, а затем построение скрытых слоев представляет собой многослойный персептрон, который и является полноценной нейронной сетью, позволяющей решать практически все задачи машинного обучения.

1.4.1 Обучение нейронных сетей

Нейронные сети, решающие различные задачи машинного обучения, отличаются друг от друга не только числом нейронов в слоях и числом слоев, а еще и методами обучения. В частности, обучение сети с учителем предполагает знание целевого значения i -ого выхода нейронной сети – d_i , с помощью которого строится целевая функция (функция потерь), подлежащая минимизации:

$$E(\theta) = \sum_{i=1}^p (y_i - d_i)^2, \quad (1.4)$$

где y_i – значение i -ого выхода нейросети, p – число нейронов в выходном слое, θ – значение веса. При обучении нейронной сети чаще всего применяется метод градиентного спуска, позволяющий на каждой итерации производить коррекцию веса $\Delta\theta$, достигая максимума функционала $E(\theta)$.

Принципиальное отличие нейронных сетей от традиционных линейных моделей заключается в характере функции потерь, которая является невыпуклой из-за нелинейной природы сети. Нелинейность нейронных архитектур обуславливает принципиально иные подходы к процессам обучения. Классические линейные модели предполагают использование аналитических методов решения математических уравнений с гарантированной сходимостью. Вместо этого нейронные сети требуют применения итеративных градиентных оптимизаторов, направленных на минимизацию функции потерь. Стохастический градиентный спуск как доминирующий метод обучения нейронных сетей не гарантирует такой сходимости и чувствителен к начальным значениям параметров.

Процесс обучения нейронной сети представляет собой сложный механизм преобразования и обработки информации. Каждый структурный компонент нейронной архитектуры выполняет свои функции, направленные на последовательное извлечение и интерпретацию релевантных признаков.

Базовым элементом нейронной сети является слой – функциональный модуль, который можно рассматривать как интеллектуальный фильтр информации. Принципиальная особенность такого модуля заключается в

селективной трансформации входных данных в более компактное и семантически насыщенное представление. Методология глубокого машинного обучения подразумевает последовательное объединение простых слоев, реализующих постепенную очистку и структуризацию информации входных данных. Каждый последующий слой осуществляет все более сложную абстракцию входных данных, выделяя наиболее значимые для решаемой задачи характеристики.

Функция потерь выступает критериальным инструментом оценки эффективности учебного процесса. Она формирует механизм обратной связи, позволяющий сети осуществлять самокоррекцию и целенаправленно свести к минимуму погрешность между прогнозируемыми и фактическими результатами.

Оптимизационный алгоритм представляет собой сложный математический механизм адаптивной настройки параметров нейронной сети. Его предназначение состоит в последовательной коррекции внутренней структуры на основании входных данных и критериев функции потерь.

Большинство современных алгоритмов оптимизации базируются на методологии градиентного спуска. Процесс обучения представляет собой итеративный поиск оптимальной конфигурации параметров модели, обеспечивающей минимизацию функции потерь на заданной обучающей выборке. Поэтому для минимизации необходимо двигаться в направлении, прямо противоположном градиенту к поверхности. Если функцию, определяющую эту поверхность обозначить через $E(\theta) = E(\theta_1; \theta_2; \dots; \theta_n)$, то ее градиент ∇E — это вектор производных функции нескольких переменных по каждой из компонент:

$$\nabla_{\theta} E = \begin{pmatrix} \frac{\partial E}{\partial \theta_1} \\ \vdots \\ \frac{\partial E}{\partial \theta_n} \end{pmatrix} \quad (1.5)$$

Градиент характеризует вектор наиболее интенсивного роста функции, а его противоположное направление $(-\nabla_{\theta} E)$, соответственно, определяет траекторию наиболее быстрого убывания функции.

Механизм обучения нейронных сетей основывается на их математической структуре как последовательности дифференцируемых тензорных операций, что позволяет использовать градиентный метод для вычисления производных параметров модели относительно функции потерь.

1.4.2 Глубокое обучение нейронных сетей

Глубокое обучение представляет собой инновационный подход в области машинного интеллекта, ключевая особенность которого заключается в многоуровневом изучении информации через последовательное наложение все более сложных абстракций.

Термин "глубокий" в контексте машинного обучения не подразумевает более глубокого понимания в классическом смысле, а характеризует многослойность модели обработки информации, то есть глубина модели определяется количеством промежуточных слоев, по которым проходят входные данные. Каждый такой слой выполняет нелинейное преобразование, что позволяет системе последовательно изымать все более сложные и содержательные признаки входных данных.

Уникальность глубокого обучения основывается на интерактивном взаимодействии между уровнями представления. Каждый слой одновременно учитывает потребности предыдущего и последующего слоев, обеспечивая непрерывную адаптацию и оптимизацию внутренней структуры искусственной нейронной сети. Помимо сказанного, к ключевым особенностям глубокого обучения относится свойство самоорганизации и автономной эволюции представлений. Глубокая сеть способна самостоятельно определять и извлекать наиболее информативные признаки, минимизируя необходимость ручной настройки.

Отличительными характеристиками глубокого обучения являются:

– принципиальная простота, которая заключается в способности создавать высокоэффективные алгоритмы без необходимости сложного предварительного выделения диагностических признаков. В отличие от классических подходов, где

исследователю необходимо приложить значительные интеллектуальные усилия для формирования информативных признаков, глубокие сети способны самостоятельно выделять и прорабатывать наиболее релевантные;

– масштабируемость, которая обеспечивается возможностью эффективной параллельной обработки на графических процессорах. Это принципиально изменяет парадигму вычислений, позволяя прорабатывать сверхбольшие массивы информации с высоким быстродействием и минимальными аппаратными затратами. Итеративный характер обучения позволяет последовательно наращивать информационную базу, осуществлять обучение на наборах данных разного масштаба и сложности. Такой подход особенно актуален при диагностировании сложных технических систем, где появляются новые информационные контексты;

– гибкость модели. В отличие от традиционных алгоритмов, требующих полной перенастройки при изменении входных данных, современные нейросетевые методы способны адаптироваться через частичное дообучение. Это обеспечивает принципиально новый уровень непрерывного интеллектуального развития систем, когда алгоритм может накапливать знания и совершенствоваться без кардинальной реконструкции базовой архитектуры.

Предлагаемый подход открывает принципиально новые горизонты интеллектуального анализа технических систем, обеспечивая качественно новый уровень возможностей диагностики.

1.4.3 Глубокие сети

Автокодировщики (автоэнкодеры [69]) – это нейронные сети прямого распространения, которые на выходе восстанавливают входные данные. Автоэнкодеры конструируются таким образом, чтобы не иметь возможности точно скопировать входные данные на выходе. Обычно это достигается за счет уменьшения размерности скрытых слоев. Входные данные восстанавливаются с потерями при кодировании, но, чтобы их минимизировать, сеть вынуждена учиться отбирать наиболее важные признаки.

Ошибка восстановления данных автоэнкодером рассматривается как оценка аномалий и образцы с высокой ошибкой реконструкции рассматриваются как аномалия. На этапе обучения используются только нормальные данные, чтобы свести к минимуму ошибки реконструкции данных, где, как считается, нет аномалий. На этапе тестирования обученный автоэнкодер сможет с минимальными ошибками восстановить нормальные исходные данные, в то время как аномальные исходные данные, с которыми автоэнкодер не сталкивался раньше, будут иметь относительно высокую погрешность реконструкции по сравнению с нормальными данными. Таким образом, путем сравнения ошибки реконструкции с определенным порогом, автоэнкодер может определить, является ли тестируемые данные аномальными.

Автоэнкодеры представляют собой эффективный инструмент для анализа многомерных данных. Их основная функция заключается в понижении признакового пространства с сохранением важной информации [70]. Они позволяют преобразовывать исходные данные в более компактное представление, выделяя при этом наиболее значимые латентные характеристики. Такой подход позволяет исследователям извлекать значимые особенности, которые раскрывают смысл и структуру исходного массива данных.

Автоэнкодеры, основанные на нейронных сетях, принципиально отличаются от классических методов понижения размерности своей гибкостью и способностью моделировать сложные многомерные пространства без жестких предварительных ограничений. В отличие от традиционных подходов, которые требуют строгих предположений о структуре данных, нейросетевые модели могут адаптивно улавливать нелинейные взаимосвязи между признаками. Такой подход позволяет извлекать более глубокие и содержательные признаки, хотя и требует более сложных вычислительных процедур. Гибкость нейронных сетей обеспечивает качественно новый уровень анализа многомерных данных, существенно расширяя возможности машинного обучения

Автоэнкодеры можно использовать совместно со стандартными методами обнаружения неисправностей, например, со статистическими критериями обнаружения [71]. Высокая степень сжатия исходных данных, с помощью нахождения сложных нелинейных зависимостей, а также возможность модернизации архитектуры, например, с целью удаления шума [72] являются преимуществами данной нейронной сети, но стоит отметить вычислительную сложность алгоритмов и сложность настройки моделей.

Кроме автоэнкодеров, к основным алгоритмам глубокого обучения в области обработки последовательностей относятся сверточные и рекуррентные нейронные сети.

Сверточные нейронные сети ориентированы на анализ локальных пространственных паттернов во входных данных. В отличие от полносвязных слоев, работающих с глобальными признаками, слои свертки концентрируются на малых областях входного пространства, что делает их чрезвычайно эффективными при обработке изображений и последовательностей.

Ключевое преимущество сверточных нейронных сетей состоит в двух определяющих свойствах: способности изучать инвариантные паттерны и формировать иерархические пространственные структуры. Операция свертки позволяет нейронной сети выделять и обобщать признаки путем применения идентичных преобразований к разным участкам входных данных.

Механизм работы таких сетей основан на использовании специализированных фильтров, которые перемещаясь по входной области обнаруживают специфические локальные характеристики. Каждый фильтр настраивается на выделение определенных пространственно-временных закономерностей, что обеспечивает высокую точность распознавания сложных паттернов.

Сверточные нейронные сети имеют широкую область применения – от компьютерного зрения до диагностики технических систем. Их архитектура

позволяет эффективно решать задачи по удалению шумов [73], кластеризации [74] и обнаружению аномалий в работе оборудования [75].

Особенно перспективны одномерные сверточные сети, способные конкурировать с рекуррентными нейронными сетями при обработке последовательностей, но с меньшими вычислительными затратами. Это достигается благодаря специальной архитектуре, позволяющей параллельно прорабатывать большие массивы данных.

В контексте технической диагностики они способны:

- выявлять скрытые закономерности в многомерных данных;
- осуществлять классификацию технических состояний;
- прогнозировать потенциальные отказы оборудования;
- обеспечивать раннее обнаружение предотказных ситуаций;

Рекуррентные нейронные сети (РНС) [76] являются мощным средством анализа временных рядов, благодаря способности «накапливать» внутреннее состояние. Они способны изучать долговременные зависимости в последовательно поступающих данных. РНС представляет собой уникальный тип нейронной архитектуры с внутренним циклическим механизмом обработки данных. Принцип их работы заключается в последовательной обработке элементов входных данных с сохранением промежуточных состояний, полученных при анализе предыдущих элементов. Такой подход позволяет сети накапливать и учитывать контекстную информацию в рамках единой последовательности, что принципиально отличает РНС от классических нейронных сетей. При переходе между независимыми последовательностями сеть обнуляет внутреннее состояние, что гарантирует корректность интерпретации каждого нового входного блока данных. Обработка последовательности происходит не единомоментно, а через итеративный внутренний цикл, где каждый элемент последовательно анализируется с учетом предыдущих состояний. Этот механизм делает РНС эффективным инструментом для работы с последовательными структурами, где важна взаимосвязь элементов.

Сети долгой краткосрочной памяти (Long Short-Term Memory – LSTM), первоначально представленные в [77], являются разновидностью РНС и отличаются улучшенным воспроизведением долговременных зависимостей.

Двунаправленные Bi-LSTM (Bidirectional LSTM) [78] на каждой эпохе обучения производят «двойной» проход по входным данным $\mathbf{x} = (x_{t_0}, x_{t_1}, \dots, \dots, x_{t_T})$ – сперва в прямом направлении по времени, от t_0 к t_T от затем в обратном, от t_T к t_0 . Bi-LSTM-сети, за счет более детальной обработки временного ряда (рекуррентный проход в прямом и обратном направлении), способны точнее запоминать характеристики входных данных.

Механизмы внимания [79,80] – это подход в машинном обучении, заключающийся в выделении части входных данных для более детальной обработки. Применение механизмов внимания позволяет улучшить выделение характеристических особенностей временных рядов, благодаря информации, полученной из взвешенной суммы всех скрытых состояний РНС. Различают два типа механизмов внимания: глобальное внимание, которое акцентируется на всей последовательности входных данных, и локальное, учитывающее только некоторую окрестность текущего состояния. В данной работе используется глобальное внимание.

1.5 Выводы к главе 1

В главе проведен обзор методов обработки данных, регистрируемых на АЭС, а также методов машинного обучения, применяемых для анализа данных. Рассмотрены основные методы предварительной обработки данных, а также методы обнаружения неисправностей и прогнозирования. Описаны преимущества и недостатки каждого метода, а также приведены ссылки как на фундаментальные научные работы, так и на прикладные исследования, подтверждающие их эффективность.

Особое внимание уделено методам машинного обучения, таким как нейронные сети, рекуррентные и сверточные нейронные сети, а также механизмам внимания. Были рассмотрены преимущества и недостатки каждого метода, а также приведены примеры их применения в промышленности.

В результате проведенного обзора систематизированы методы обработки данных, собираемых на АЭС, и методы машинного обучения, применяемые для анализа и прогнозирования развития аномалий. Описаны их преимущества и недостатки, а также требования к исходным сырым данным. Проведен сравнительный анализ методов и даны рекомендации по выбору методов для решения конкретных задач.

Проведенное исследование демонстрирует перспективность применения современных методов машинного обучения и анализа данных в атомной энергетике. Использование передовых подходов открывает новые возможности для более точного контроля состояния и диагностирования объектов АЭС, что напрямую влияет на безопасность и эффективность их функционирования. Потенциал развития данных методов связан с возможностью создания интеллектуальных систем управления и раннего обнаружения нештатных ситуаций. Однако, для практического применения в промышленности, необходимы дальнейшие исследования и разработки алгоритмов, способных обрабатывать большие объемы данных в режиме реального времени.

Следует отметить, что в большинстве своем разработчики ориентируются на опыт эксплуатации, знания процессов и последствий аномальных ситуаций. Также важно отметить, что традиционный подход позволяет выявить неисправности, которые уже интенсивно развиваются. Таким образом, разработка предиктивных методов и алгоритмов для систем диагностирования оборудования АЭС, предлагающих точный диагноз всевозможных аномалий, приведет к повышению качества выявления дефектов оборудования и оценки их характеристик.

Глава 2. Фильтрация глобальных шумов измерительных каналов систем контроля течи трубопроводов ГЦК РУ с ВВЭР

Одной из важнейших задач обеспечения безопасной эксплуатации АЭС является контроль герметичности оборудования первого контура. Для предотвращения разрывов трубопроводов контура теплоносителя разработана и применяется концепция «течь перед разрушением» (ТПР) [81], которая состоит в обосновании факта, что разрыву трубопроводов предшествует образование стабильной сквозной трещины. Для своевременного обнаружения сквозной трещины на АЭС используется система акустического контроля течи (САКТ), но в ходе ее эксплуатации были выявлены помехи, не позволяющие обнаруживать протечки с заданной концепцией ТПР чувствительностью. Действительно, отличительной особенностью РУ как источника акустических шумов, является сложность протекающих в ней процессов с множеством трудно учитываемых связей. Эти процессы имеют различную физическую природу: механические, гидродинамические, вибрационные, ударные, связанные с генерацией и барботажем пара и т.д. Все это порождает множество акустических источников, действующих в различных диапазонах частот, зависящих от режима работы установки, состава действующего оборудования и множества других факторов. Посторонние шумы могут быть сравнимы по амплитуде с полезным сигналом при течи, что может приводить к ложным срабатываниям системы диагностирования.

Технологические шумы распространяются по поверхности металла и проявляются в показаниях большинства измерительных каналов в большей или меньшей степени, в зависимости от места установки датчика. Это обстоятельство вызвало необходимость разработки алгоритма фильтрации фоновых шумов, который базируется на прогнозировании сигнала заданного измерительного канала, проведенного по регрессионной модели, построенной на основе принципа информационной избыточности. Кроме того, в данном разделе исследована

устойчивость предложенного алгоритма к различным фоновым акустическим выбросам.

2.1 Формирование диагноза на основе анализа акустических сигналов

При разработке настоящего алгоритма предполагается [82], что глобальные шумы РУ одинаково фиксируются всеми измерительными каналами акустической системы. Поскольку причина этих шумов для измерительного канала (ИК) каждой петли общая (что подтверждается коэффициентами взаимной корреляции сигналов, среднее значение которых составляет 0,65), то сигналы в присутствии помех можно представить в векторном виде:

$$s(t) = q(t) + \delta(t), \quad (2.1)$$

где $s(t)$ – показания ИК в системе, $q(t)$ – глобальная помеха, $\delta(t)$ – локальный сигнал.

Таким образом, задача фильтрации глобальных шумов сводится к нахождению неизвестной функции $q(t)$ и вычитанию ее из известного сигнала $s(t)$. Значения показаний любого ИК $s_i(t)$ на i -ом участке можно выразить через показания ИК на соседних участках с помощью регрессионной модели. Этот подход был предложен в работе [83], где в качестве регрессионной модели использовался метод группового учета аргументов (МГУА). В предлагаемом ниже алгоритме исследовано два вида регрессионных моделей: двуслойная нейронная сеть, на основе которой строилась нелинейная регрессия, и линейная байесовская робастная регрессионная модель. По сравнению с [83] удалось достичь хороших результатов по предсказанию глобальных акустических шумов за счет использования именно байесовской робастной регрессионной модели и Калмановской фильтрации остаточного сигнала.

Регрессия строилась для каждого сигнала ИК на определенном участке РУ в зависимости от сигналов всех ИК, расположенных на других петлях (на оставшихся 3 петлях), а также от сигналов других ИК той же самой петли

Таким образом, для каждого сигнала было получено по 4 зависимости. Сначала для определения этих зависимостей использовалась нейронная сеть [84] с одним входным слоем, одним скрытым слоем размером 30 и одним выходным:

$$q_i(t) = \text{net}(s_i(t), \sum_j s_j(t)), \quad (2.2)$$

где $s_i(t)$ – сигнал i -ого ИК, для которого строились регрессии, а $s_j(t)$ – сигналы ИК другой петли или участков, по которым считалась регрессия. $q_i(t)$ – вектор глобальных шумов для i -го ИК, рассчитанный по различным регрессиям, net – обученная нейронная сеть, состоящая из двух полносвязных слоев с 30 нейронами в каждом, в которую подставляются значения сигналов ИК $s_j(t)$.

Данная регрессионная модель является нелинейной и поэтому даже небольшие изменения в работе измерительных каналов могут приводить к значительным отклонениям в результатах при ее применении. На рисунке 2.2 приведены результаты применения двух различных регрессионных моделей к сигналу первого акустического ИК системы акустического контроля течей Нововоронежской АЭС-2 (Энергоблок №1).

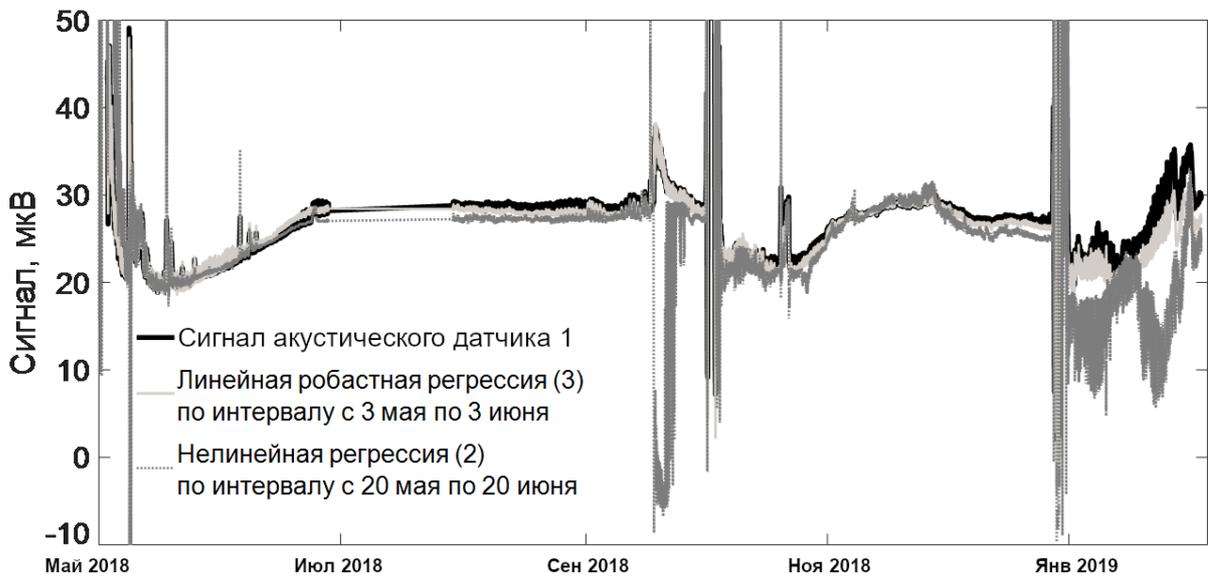


Рисунок 2.2 – Применение регрессионных моделей к сигналу акустического ИК №1 за кампанию 2018 – 2019 годов

Кривая на графике рисунка 2.2 получена в результате применения линейной робастной байесовской регрессионной модели [85,86,87]:

$$q_i(t) = \sum_j \beta_j s_j(t) + \xi(t), \quad (2.3)$$

где $\xi(t)$ ошибка регрессии, имеющая распределение Стьюдента.

Распределение Стьюдента имеет более толстые «хвосты», чем нормальное распределение и поэтому намного более устойчиво к различным выбросам в данных [85]. В отличие от гауссова распределения, когда решение задачи сводится к нахождению псевдообратной матрицы в методе наименьших квадратов, здесь приходится непосредственно решать задачу минимизации отрицательного логарифма правдоподобия от распределения Стьюдента.

Расчеты показали, что для приемлемого воспроизведения данных за всю кампанию, достаточно построить регрессию за 1 день.

В сигналах акустических ИК во время разогрева и расхолаживания РУ возникают резкие пики, что напрямую связано с работой ГЦН. Эти акустические выбросы очень значительны – их величина порядка 5000 мкВ. При таких сигналах отклик акустических датчиков является сильно нелинейным и определять наличие течи становится невозможно. Интегральный сигнал, фактически, представляет собой дисперсию реального сигнала и, следовательно, сигнал от течи квадратично складывается с фоновым сигналом. То есть

$$U_{tot}^2 = U_{фона}^2 + U_{течи}^2, \quad (2.4)$$

где $U_{фона}$ – фоновый сигнал, $U_{течи}$ – сигнал течи и U_{tot} – суммарный сигнал.

С помощью полученных регрессионных зависимостей для каждого ИК рассчитывались значения акустических сигналов с отфильтрованным глобальным шумом: $\delta_i^j(t) = s_i(t) - q_i^j(t)$, где i – номер ИК, а j – номер регрессионной зависимости. Таким образом, если течь возникает на каком-либо участке трубопровода, то возможны две различные ситуации:

1) Течь возникла на участке с рассматриваемым ИК. Тогда все величины $\delta_i^j(t)$ будут изменяться в соответствии с шумом, вызываемым течью и $\delta_i(t) = |\min_j(\delta_i^j(t))|$ – это искомый сигнал течи, с отфильтрованными глобальными шумами, который сравнивается с заданными уставками.

2) Течь возникла на другом участке – j . Тогда регрессионная зависимость $q_i^j(t)$ для данного ИК будет неверной, однако остальные $q_i^k(t)$, где $k \neq j$ будут давать правильные величины и выражение $\delta_i(t) = |\min_{(k)} \delta_i^k(t)|$ останется верным, и величина $\delta_i(t)$ для i -го ИК не будет содержать сигнала течи. Здесь нужно отметить, что чем больше регрессий мы будем рассматривать, тем надежней будет результат. То есть, если мы будем рассматривать регрессии не суммарно от всех ИК, расположенных на соседних петлях, а от ИК, расположенных на каждом участке всех петель, то вместо 4-х получим 11 регрессий для каждого ИК, расположенного на одной петле.

Результирующая величина $\delta_i(t)$ представляет собой наблюдаемый случайный сигнал, который содержит в себе ошибку измерений, а также ошибку фильтрации глобального шума (регрессионной зависимости). Чтобы получить из него оптимальный сигнал рассмотрим задачу в модели пространства состояний, где оптимальность решения достигается за счет применения фильтра Калмана [88,89,90,91].

Модель системы подразумевает, что реальное скрытое состояние в момент времени $t+1$ получается из состояния в момент времени t согласно уравнению состояния:

$$\mathbf{x}(t+1) = \mathbf{A} \cdot \mathbf{x}(t) + \boldsymbol{\varepsilon}(t), \quad (2.5)$$

где \mathbf{A} – матрица пространства состояний, $\boldsymbol{\varepsilon}$ – вектор ошибки пространства состояний, а вектор измерений $\delta_i(t)$ связан с вектором состояния системы следующим уравнением:

$$\delta_i(t) = \mathbf{C} \cdot \mathbf{x}(t) + \boldsymbol{\omega}(t) \quad (2.6)$$

Здесь \mathbf{C} – матрица измерений, $\boldsymbol{\omega}$ – вектор ошибки измерений.

Итерация фильтра Калмана делится на две фазы: предсказание и учет наблюдений. Фаза предсказания использует вычисленное на предыдущем шаге состояние для получения через модель системы оценочного состояния на текущем шаге. В фазе учета наблюдения информация об измерениях, произведенных на текущем шаге, используется для уточнения информации о состоянии системы, что

в результате делает её более точной. Фильтр Калмана является оптимальным способом получить измеряемый в линейной системе с гауссовым шумом сигнал наиболее близким к его реальной величине.

На рисунке 2.3 приведены графики первоначальных сигналов $s_i(t)$ и отфильтрованные от глобальных шумов с помощью регрессий и оптимизированные фильтром Калмана сигналы $\delta_i(t)$. Очевидно, что вероятность ложных срабатываний с очищенными от глобальных шумов сигналами значительно снижается.

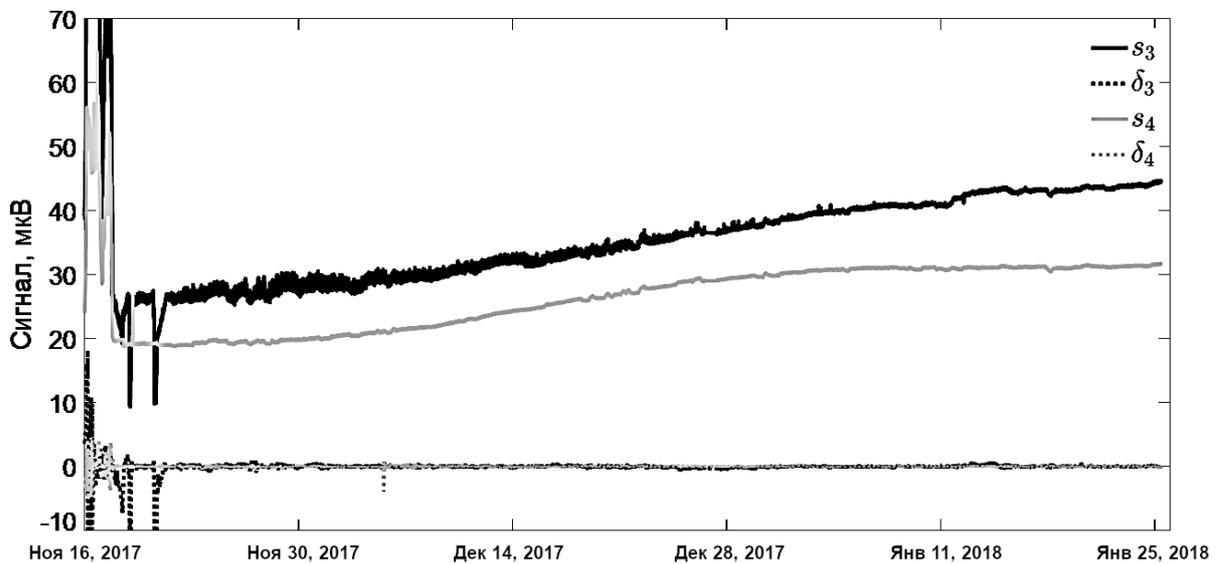


Рисунок 2.3 – Величина сигналов $s_i(t)$ и $\delta_i(t)$ для некоторых акустических ИК САКТ НВАЭС-2 (Энергоболок №1)

Рассмотрим, как изменится величина $\delta_i(t)$ на j -ом участка трубопровода, если где-то на другом участке выйдет из строя акустический ИК. В этом случае, регрессионная зависимость глобального шума для акустических ИК на участке j от участка с неисправным ИК будет неверная. Однако в результате работы предложенного выше алгоритма результирующая величина $\delta_i(t)$ не будет сильно отличаться от того случая, когда все акустические ИК на всех участках работали нормально. Результат рассмотренной ситуации приведен на рисунке 2.4а и рисунке 2.4б.

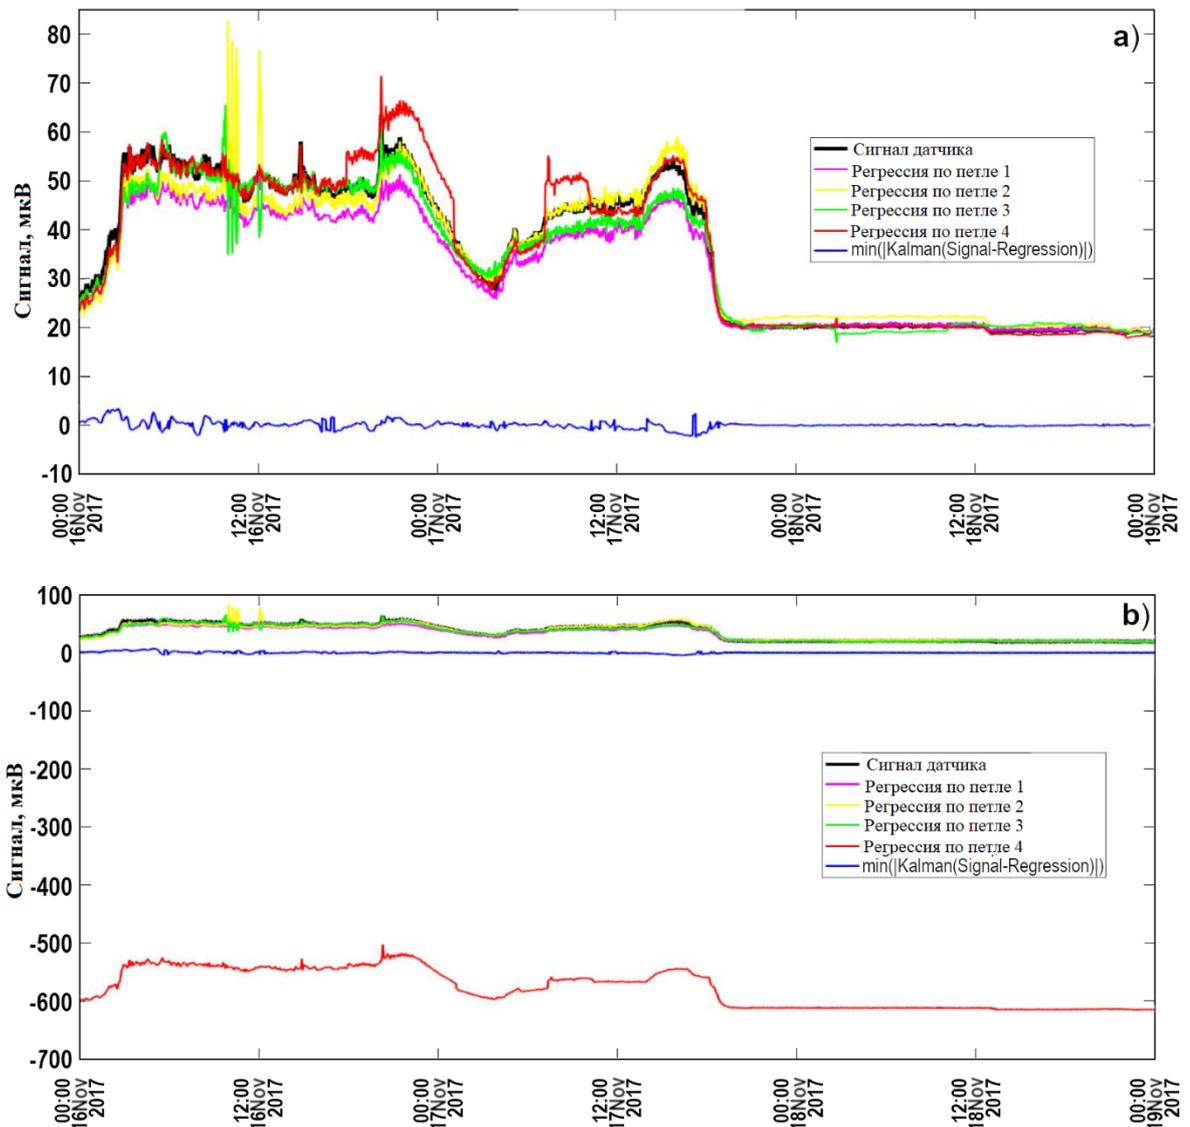


Рисунок 2.4 – Сигналы, регрессии и $\delta_i(t)$ для 1-го акустического ИК НВАЭС -2 (Энергоблок №2) для штатной ситуации – а), и в случае неисправности 32-го ИК (петля 4) – б)

На рисунке 2.4а показана штатная ситуация, а на рисунке 2.4б искусственно изменены показания акустического ИК № 32 на U-образном изгибе четвертой петли на 500 мкВ. Величины $\delta_i(t)$, полученные для данного ИК по четырем и по трем регрессиям, почти не отличаются. В дальнейшем планируется рассматривать зависимость сигнала каждого ИК не просто от сигналов ИК, расположенных на других петлях, а от ИК, расположенных на других участках. Тогда получим 11 регрессий вместо четырех (поскольку на каждой петле находится три участка), что позволит алгоритму достичь гораздо большей надежности и устойчивости результатов в случае выхода из строя ИК на других участках.

2.2 Моделирование течи теплоносителя ГЦК

Покажем, как алгоритм будет обрабатывать при повышении сигналов. Для этого к текущим показаниям акустических ИК на холодном участке первой петли (номера ИК – 1, 2 и 3) были добавлены сигналы, плавно изменяющиеся от 0 до 300 мкВ и имитирующие течь на данном участке трубопровода.

Поскольку на 6-м блоке ВВЭР-1200 Нововоронежской АЭС-2 (Энергоблок №2), экспериментальные данные с которой были использованы в данной работе, истечений из контурных элементов не происходило, то были использованы модельные данные, полученные на основе экспериментального обоснования САКТ на специализированном стенде, а также имеющихся данных по протечкам на номинальных параметрах эксплуатируемых РУ.

Исходные технические требования к разработке САКТ, содержат требование по обнаружению протечки теплоносителя от 3,9 литров в минуту. Поэтому по результатам экспериментального обоснования САКТ была определена величина чувствительности акустического сигнала к течи как 55 мкВ на литр в минуту. Исходя из этого, порог акустического сигнала протечки определен как 200 мкВ.

Для примера, на рисунке 2.5а показано, как ведет себя величина $\delta_1(t)$ для данного участка трубопровода, а на рисунке 2.5б – поведение сигнала ИК 14 и величины $\delta_{14}(t)$ на участке, на котором нет имитации течи, но участок с течью участвует в регрессионном анализе значений сигналов ИК. Очевидно, что течь присутствует только на том участке, для которого она имитируется, хотя регрессия по участку с течью (по петле 1 на Рисунке 2.5б) неверна. Таким образом в результате работы алгоритма наличие течи наблюдается только на том участке, на котором она имитируется.

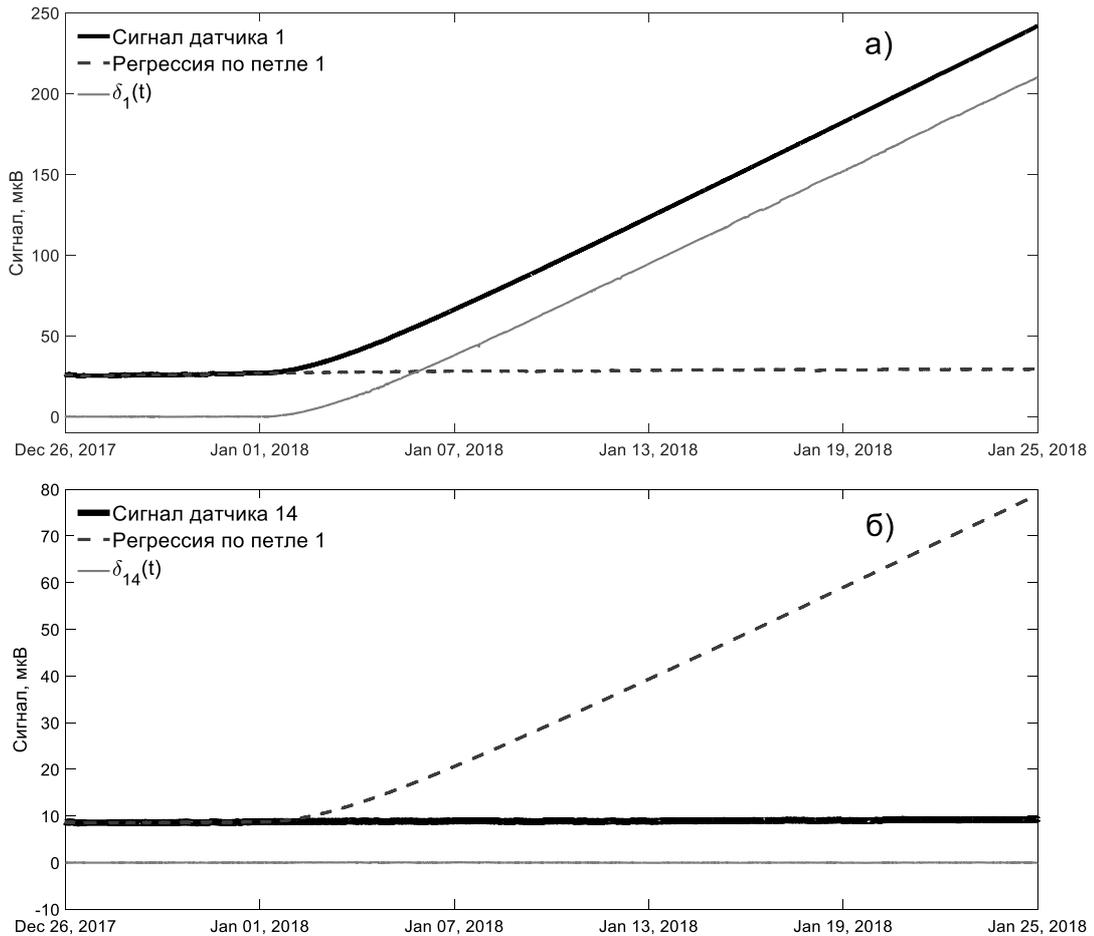


Рисунок 2.5 – Величины $\delta_i(t)$ для участка трубопровода с течью – а) и для участка трубопровода без течи – б)

2.3 Выводы к главе 2

В данной главе были рассмотрены системы акустического контроля течи на АЭС с реакторной установкой ВВЭР-1200 и разработан новый метод фильтрации глобальных шумов на основе принципа информационной избыточности, который обеспечивает более точную диагностику течей.

Полученный алгоритм позволяет значительно повысить надежность определения протечек трубопроводов РУ, сократив число ложных срабатываний, и повысить чувствительность к течи до уровня достаточного для обнаружения течи с расходом, установленным концепцией ТПР.

Алгоритм включает в себя построение нескольких регрессионных моделей для каждого сигнала ИК. Для построения моделей использовались двуслойная нейронная сеть и линейная байесовская робастная регрессионная модель. По результатам экспериментов выяснилось, что использование байесовской робастной регрессионной модели и калмановской фильтрации остаточного сигнала позволяет достичь хороших результатов по предсказанию глобальных акустических шумов и выделению полезного сигнала. Регрессии строились для каждого сигнала ИК на определенном участке РУ в зависимости от сигналов всех ИК, расположенных на других петлях, и сигналов ИК других участков той же петли.

Практическая работоспособность алгоритма продемонстрирована путем моделирования течи на данных, полученных на основе экспериментального обоснования САКТ на специализированном стенде и на имеющихся данных по протечкам на номинальных параметрах, эксплуатируемых РУ.

Предложенный метод фильтрации глобальных шумов обеспечил более точную диагностику течей и используется в системе САКТ НВАЭС-2 (Энергоблок №2).

Глава 3. Алгоритм определения неисправности измерительных каналов системы акустического контроля течи

Надежность определения течи системой САКТ в значительной степени зависит от количества работоспособных акустических датчиков (АД) или каналов системы. Поэтому для увеличения надежности САКТ необходимо постоянно контролировать работоспособность акустических каналов. В САКТ предусмотрена самодиагностика измерительных каналов, а также применен адаптивный алгоритм, позволяющий автоматически перестроиться на использование соседних ИК взамен вышедших из строя. Вместе с тем, возможны такие неисправности технических средств системы, которые не позволяют автоматически диагностировать неисправность ИК, что может привести к невыполнению функции системы по определению величины и координаты течи теплоносителя первого контура.

В связи с этим, актуальна задача разработки алгоритмов определения неисправности ИК системы САКТ [92], реализуемых с применением программного обеспечения без внесения изменений в технические средства системы.

В состав системы САКТ входят акустические датчики (АД) GT-400 производства ООО «ГлобалТест», г. Саров, которые имеют встроенные пьезоизлучатели, что позволяет без демонтажа оборудования проводить проверку работоспособности измерительных каналов, включая калибровку с рабочего места системы комплексного диагностирования [5] (СКД).

Проверка работоспособности ИК САКТ заключается в следующей последовательности [93]:

- на встроенный пьезоизлучатель АД подается импульсный сигнал со следующими параметрами: частота следования импульсов $f = 11$ кГц, амплитуда импульсов 2.5 В, длительности импульсов 5 мкс;

- благодаря обратному пьезоэлектрическому эффекту происходит возбуждение АД, в результате чего он испускает выходной сигнал;
- длительность тестового воздействия на встроенный пьезоизлучатель составляет 3 секунды;
- измерение и регистрация дисперсии выходного сигнала АД ведется с периодичностью раз в секунду;
- сравнивая среднее значение дисперсии выходного сигнала АД за период тестирования с референтным значением, полученным во время наладки системы, получаем вывод об исправности измерительного канала;

Проверка работоспособности ИК САКТ проводится группами, причем группы подобраны так, чтобы близлежащие АД находились в различных группах для исключения влияния тестового сигнала на показания соседних датчиков [9]. Периодичность проверки работоспособности ИК САКТ – один раз в час.

Предлагается увеличить длительность тестового воздействия на встроенный в АД пьезоизлучатель до 60 секунд, а вывод об исправности ИК САКТ делать, в том числе, на основе статистических характеристик отклика АД на тестовое воздействие [92]. Периодичность проверки работоспособности ИК САКТ один раз в час в таком случае представляется избыточной, и поэтому предложено проводить автоматическую проверку ИК САКТ один раз в сутки. Помимо этого, для удовлетворения требованиям концепции ТПР о времени фиксации факта течи (которое не должно превышать 3 минуты), тестовые воздействия между группами АД должны быть разнесены по времени для обеспечения непрерывной работы САКТ.

3.1 Анализ данных тестового воздействия

Исходными данными для проверки работоспособности ИК САКТ являются отклики АД на тестовые воздействия длительностью 60 секунд.

В таблице 3.1 приведены номера АД, разбитых на четыре группы таким образом, чтобы тестовый сигнал, приходящий на АД одной группы, никак не влиял на АД других групп.

Таблица 3.1 – Разбивка АД САКТ по четырем группам

I группа	II группа	III группа	IV группа
1	2	3	13
4	5	6	15
7	8	9	17
10	11	12	19
14	21	22	23
16	24	25	26
18	27	28	29
20	30	31	32
33	34	35	36
39	40	37	38
41	45	42	43
44	49	46	51
47	54	50	52
48	57	55	59
53	60	58	
56	62	61	

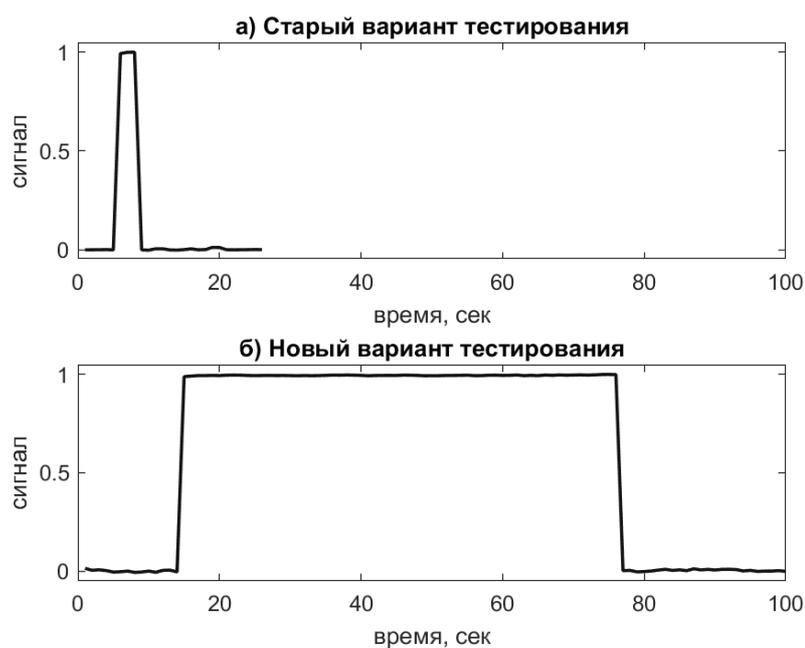


Рисунок 3.1 – Сигналы АД №16, нормированные на максимальное значение

На рисунке 3.1 приведены отклики на тестовый сигнал ИК №16, нормированные на максимальное значение (приведенные к интервалу [0;1]). На Рис. 3.1 а) приведены отклики на тестовый сигнал для предыдущего варианта тестирования, а на Рис. 3.1 б) приведены отклики на тестовый сигнал для нового варианта.

3.2 Обоснование алгоритма обнаружения неисправности ИК САКТ

Изложенный в данной работе алгоритм направлен на обнаружение неисправностей 2-х типов:

– ИК с наведенной помехой. Неисправным ИК считается тот, у которого проявляется отклик на тестовый сигнал АД из других групп (Рис. 3.2 б));

– неисправный АД. Неисправным АД считается тот, у которого дисперсия отклика на тестовый сигнал значительно больше дисперсии фона (Рис. 3.2 в)). Очевидно, что неисправный АД может быть определен только при использовании нового метода тестирования [8,94].

Для анализа применимости алгоритма [65,95,96] были использованы данные ИК САКТ с НВАЭС-2 (энергоблок №1) за период с 03.07.2019 г. по 29.07.2019 г. Предварительно для всех групп ИК выделялся фрагмент, соответствующий проверке работоспособности всех ИК системы, который включал в себя четыре последовательных тестовых интервала (по одному на каждую группу в соответствии с таблицей 1) продолжительностью 60 секунд и фоновыми интервалами между ними равными 30 секундам (т.е. последовательно подавался тестовый сигнал длительностью 60 с на первую группу АД, через 30 с подавался тестовый сигнал длительностью 60 с на вторую группу АД и т.д.).

Далее значения фона центрировались относительно нуля, а отклики на тестовый сигнал нормировались на максимальное значение.

В ходе анализа данных было выделено три группы ИК (примеры всех групп приведены на рисунке 3.2):

- 1) исправные ИК без помех в канале (рисунок 3.2 а)),
- 2) неисправные ИК с наведенными помехами в канале (рисунок 3.2 б)),
- 3) неисправные АД с повышенной дисперсией сигнала во время теста (рисунок 3.2 в)).

Все данные были размечены вручную согласно группам, приведенным на рисунке 3.2.

3.3 Классификация сигналов тестового воздействия

В работе решается задача классификации тестовых сигналов на три описанных выше класса [97]. В качестве классификатора использовалась нейронная сеть. Для увеличения точности процесс классификации был разбит на два этапа [98]. На первом этапе разбиение происходило на две группы: исправные ИК (Рис. 3.2 а)) и дефектные ИК. На втором этапе сигналы из группы неисправных ИК разбивалась еще на два класса: исправный АД с наведенной помехой в ИК (Рис. 3.2 б)); и неисправный АД с помехой в ИК (Рис. 3.2 в)).

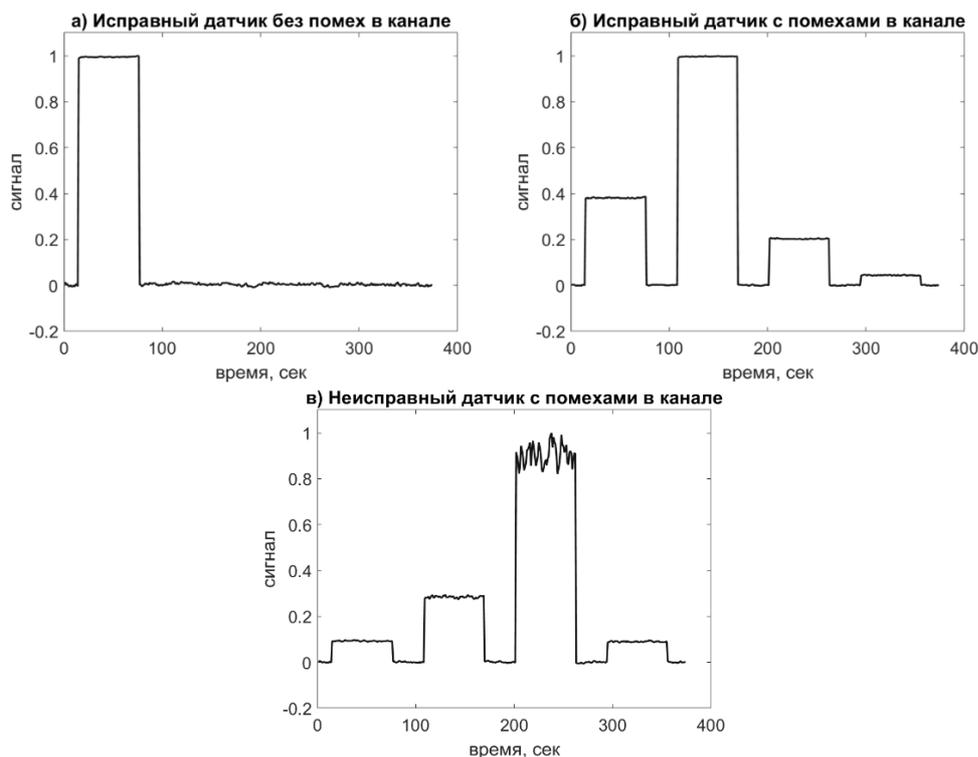


Рисунок 3.2 – Примеры тестовых сигналов ИК, принадлежащих разным классам (значения сигналов нормированы на максимальное значение)

Структура нейронной сети (Таблица 3.2) для первого и второго классификатора одинакова и состоит из следующих слоев:

1) входного слоя с числом входов равным размерам выделенных фрагментов сигналов для обучения – 374 точки;

2) первого скрытого полносвязного (*Fully Connected*) слоя с числом нейронов 190;

3) слоя активации *ReLU*, который выполняет пороговую операцию для каждого элемента входного сигнала, где любое значение меньше нуля устанавливается равным нулю:

$$f(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (3.1)$$

4) второго скрытого полносвязного слоя с числом нейронов, определенным экспериментальным путем 80;

5) выходного полносвязного слоя, за которым следует слой *Softmax*, преобразующий значения выходного вектора в вещественные числа в интервале $[0,1]$ с суммой, равной 1;

б) выход классификатора – классификационный слой, который вычисляет потери перекрестной энтропии и выдает вероятность принадлежности данного фрагмента сигнала к определенному классу.

Таблица 3.2 – Структура нейронной сети

№	Слой
1	Последовательный вход
2	Полносвязный слой 1
3	<i>ReLU 1</i>
4	Полносвязный слой 2
5	<i>ReLU 2</i>
6	Полносвязный слой 3
7	<i>Softmax</i>
8	Выход классификатора

Для корректной работы нейронной сети группы сигналов должны быть сбалансированы, т.е. содержать одинаковое количество данных. В случае если данных недостаточно, необходимо произвести расширение группы (аугментацию) [99]. Для аугментации групп сигналов был выбран метод зеркального отражения сигналов с добавлением гауссового шума с дисперсией равной дисперсии фона (Рис. 3.3) [8].

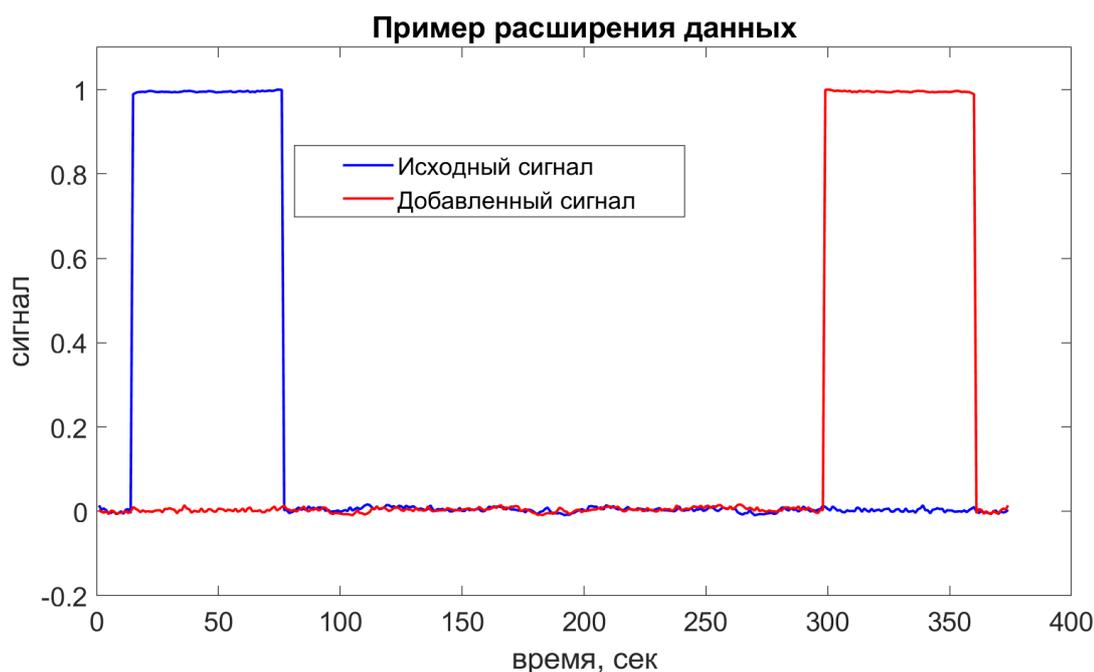


Рисунок 3.3 – Аугментация данных тестового воздействия с помощью зеркального отражения

На втором этапе аугментация не потребовалась, так как объемы групп были сопоставимы. Далее, размеченные данные использовались для обучения нейронной сети.

Для оценки качества работы алгоритма [100] на каждом из классов в отдельности, использовалась метрика *recall* (полнота) – она показывает, какую долю объектов, реально относящихся к положительному классу, мы предсказали верно:

$$recall = \frac{TP}{TP + FN} \quad (3.2)$$

где *TP* – истинно-положительное решение, а *FN* – ложно-отрицательное решение.

В результате обучения нейронной сети на обучающих данных удалось достичь полноты около 95% (Рис. 3.4).

Обученные нейронные сети были проверены на тестовых данных – сигналах АД САКТ НВАЭС-2 (энергоблок №1) за период с 01.10.2019 г. по 13.10.2019 г (Рис. 5). Результаты классификации на первом и втором этапах приведены на рисунках 3.4 и 3.5 соответственно.

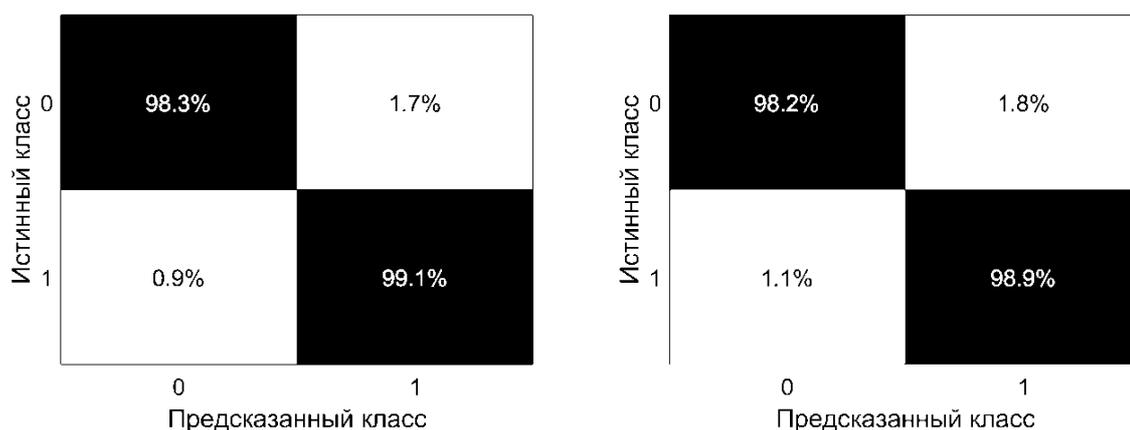


Рисунок 3.4 – Результаты классификации на обучающих данных на первом этапе (слева) и на втором этапе (справа)

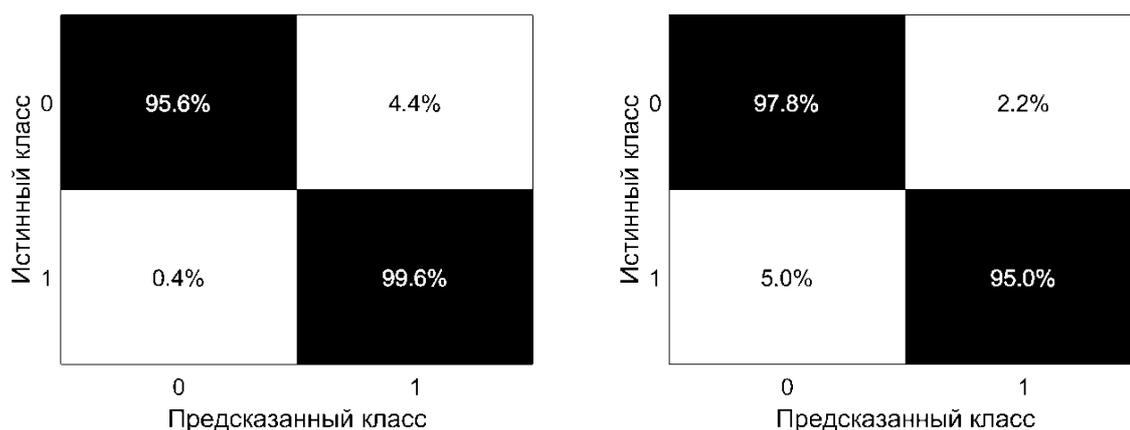


Рисунок 3.5 – Результаты классификации на тестовых данных на первом этапе (слева) и на втором этапе (справа)

3.4 Формирование диагноза о наличии неисправности

Для минимизации ложных срабатываний используется информация последних 10 тестовых сигналов АД. Сигнал о неисправности АД или в измерительном канале формируется только в том случае, если классификатор зафиксирует неисправность не менее чем в 8 случаях из 10.

В качестве примера на рисунке 3.6 приведен результат работы алгоритма, который выявил неисправность в 38-ом измерительном канале. В рассматриваемом ИК видно, что неисправен сам АД (увеличенная дисперсия во время тестового сигнала), в то время как сам ИК исправен.

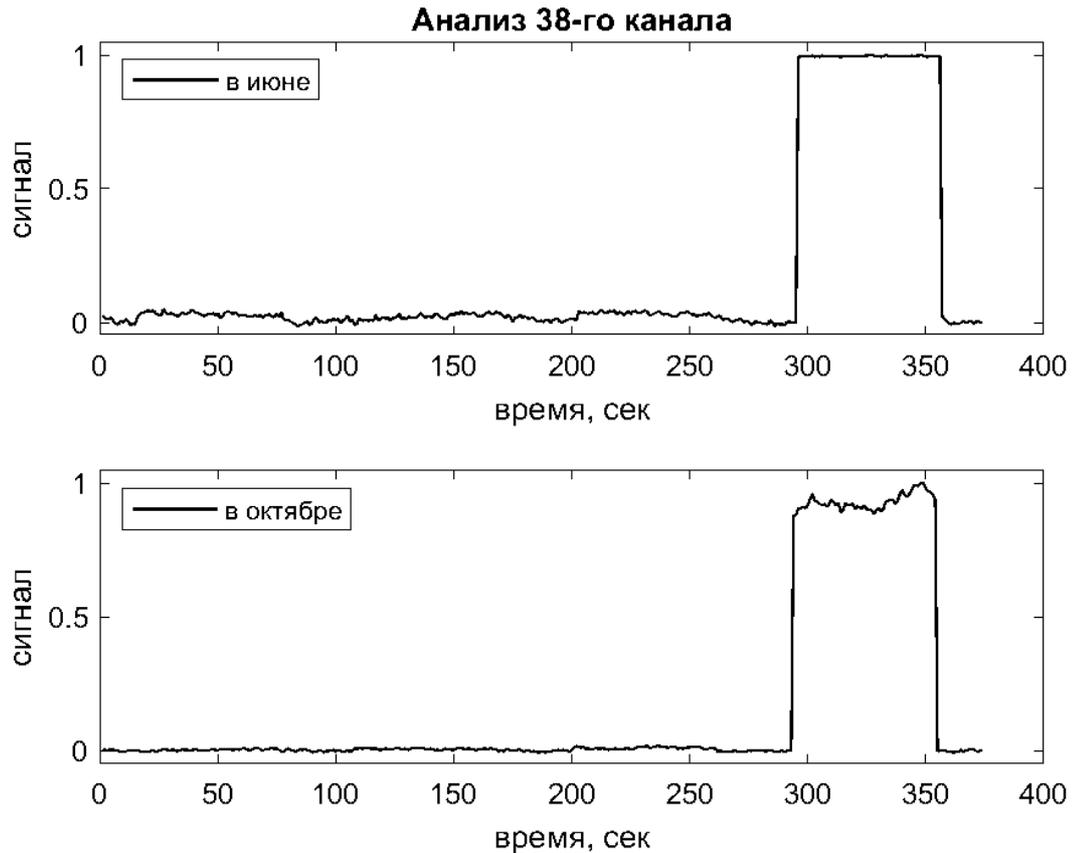


Рисунок 3.6 – Результат работы алгоритма 38-ом ИК

3.5 Выводы к главе 3

Разработан новый алгоритм выявления неисправностей в измерительных каналах и системах акустического контроля течи на АЭС ВВЭР. Он основан на использовании двух обученных нейронных сетей, способных выявлять дефекты в каналах с высокой точностью. Алгоритм был проверен на целевых данных, что подтвердило его способность детектировать не только наведенные помехи в измерительных каналах, но и определять неисправные акустические датчики. Это позволяет своевременно заменять неисправные компоненты, что ведет к повышению надежности акустической системы определения течи.

Предложенный алгоритм может быть реализован в программном обеспечении без внесения изменений в технические средства системы. Его

преимуществом является способность детектировать неисправности в измерительных каналах систем акустического контроля течи на АЭС ВВЭР с высокой точностью. Минимизация ложных срабатываний в результате использования информации о последних 10 тестовых сигналах АД позволяет снизить количество ошибок и повысить эффективность работы алгоритма.

Таким образом, результаты исследований показывают, что предложенный алгоритм имеет большой потенциал для применения в системах акустического контроля течи на АЭС ВВЭР и может быть использован для повышения надежности и эффективности работы этих систем.

Глава 4. Обнаружение аномалий в работе реакторного оборудования

Проблема обнаружения аномалий в работе технически сложного оборудования алгоритмами, основанными на методах машинного обучения и, в частности, на нейросетевых методах, в последнее время очень актуальна во многих отраслях промышленности, в том числе и в атомной энергетике. Поэтому крайне актуальным становится внедрение предиктивных аналитических систем в целях углубленной обработки данных технологического контроля для раннего обнаружения неисправностей оборудования, а также для анализа его ресурсных характеристик. Основной задачей предиктивной аналитики является построение и оптимизация цифровой модели для поиска аномалий в работе оборудования, прогнозирования временного интервала безаварийной работы оборудования и корректировка объема технического обслуживания и ремонта [101].

В данной главе предложены два алгоритма обнаружения аномалий:

– метод оценки многомерного состояния (Multivariate State Estimation Technique – MSET), основанный на сравнении наблюдаемых значений показателей с модельными и на анализе рассогласований этих значений. Нетипичные рассогласования могут свидетельствовать об аномальном поведении объекта;

– нейронные сети. В процессе обучения нейронная сеть выявляет сложные зависимости между входными и выходными данными, а также выполняет обобщение данных. В результате обучения создается модель объекта, задающая связи между моделируемыми технологическими параметрами и параметрами аргументами.

Существующий принцип технической диагностики оборудования АЭС заключается во взаимодополняющем применении систем оперативного диагностирования в процессе эксплуатации и средств неразрушающего контроля в процессе планово-предупредительных ремонтов (ППР). Как правило, оперативное диагностирование направлено не на долгосрочное прогнозирование

состояния оборудования, а на решение задачи «здесь и сейчас» по мгновенному временному срезу многоканальных измерений. Неразрушающий контроль, поставляя большую глубину диагностирования, не обеспечивает требуемую достоверность обнаруживаемых аномалий. Однако в настоящее время в атомной отрасли все шире применяются методы предиктивной аналитики в задачах диагностики [101].

Предлагаемый здесь подход состоит в обучении моделей (как нейронной сети, так и MSET) на довольно большом временном интервале работы блока АЭС в стационарном, номинальном (100%-ом) режиме функционирования, например, в течение нескольких месяцев с довольно маленьким временным шагом, например, в несколько десятков минут. То есть речь идёт о так называемых больших данных (Big Data), которые в настоящее время не анализируются системами оперативного диагностирования. При этом мощность блока действительно представляет собой практически стационарный временной ряд, а некоторые другие измеряемые параметры (например, концентрация борной кислоты или перемещения органов управления), напротив – сугубо нестационарные процессы. Обученные такими векторными синхронно измеренными процессами модели представляют собой виртуальную модель объекта диагностирования.

Любая аномалия (дефект, отказ, неисправность) в измерениях проявляется в виде нестационарности некоторых наблюдаемых временных рядов. Это не только мгновенные скачки амплитуды измерений, но и медленные тренды, практически невидимые за время наблюдений. Необходимо отличать штатную нестационарность от аномальной нестационарности. Правильно обученная и правильно выбранная модель «знает» штатную нестационарность и способна выявить новую нестационарность как аномальное состояние объекта диагностирования.

К недостаткам традиционных нейронно-сетевых методов зачастую относят необходимость обучения «с учителем». Поэтому в последнее время возрос

интерес к методам обучения «без учителя», а именно: вариационного автоэнкодера (ВАЭ) [102] и состязательных генеративных сетей [103]. В данной работе для обнаружения аномалий в качестве нейронной сети используется ВАЭ [102]. На вход ВАЭ подаются исследуемые данные, которые, проходя через структуру нейронной сети, преобразуются в выходные «восстановленные» данные, воспроизводящие для системы в нормальном состоянии входные данные с высокой точностью. По сравнению с входным вектором измерений латентное пространство ВАЭ намного меньше по размерности, то есть внутри ВАЭ происходит сжатие входной информации, но при этом сохраняется наиболее важная диагностическая информация об объекте. Такая особенность работы ВАЭ выгодно отличает его от более простых нейронно-сетевых методов, в которых нет критерия достоверности виртуальной модели объекта, полученной субъективным обучением.

В данной работе для обнаружения аномалий:

- реализован ВАЭ с механизмом внимания, на основе двунаправленных рекуррентных нейронных сетей, использующий гауссово распределение для представления латентных переменных, определяющих внутреннюю структуру исследуемых временных рядов [102], и использована вероятностная реконструкция исходных величин, что позволяет определять параметры распределения вероятностей восстановленных величин;
- реализован метод MSET, с комбинированным способом формирования матрицы памяти [104] и применением гауссова ядерного оператора;
- построен обнаружитель аномалий на основе T^2 -статистики.

4.1 Метод оценки многомерного состояния

Multivariate state estimation technique (метод оценки многомерного состояния) — это усовершенствованная технология распознавания образов,

которая позволяет получить оценку состояния путем измерения сходства между различными параметрами мониторинга в нормальном рабочем диапазоне [105].

Метод оценки многомерного состояния основан на нахождении зависимостей между признаками, с использованием данных репрезентативной выборки (соответствующей условиям нормальной эксплуатации) [9]. Основные этапы оценки аномалий в работе оборудования на основе MSET приведены ниже.

4.1.1 Выбор тренировочных данных

Тренировочные данные представляют собой матрицу, которая содержит сведения о различных исторических состояниях. Данные, предназначенные для обучения, должны удовлетворять требованиям [105]:

- должны включать динамические состояния изменения параметров контроля технического состояния;
- обучающие данные не могут содержать промежуточных состояний.

4.1.2 Создание матрицы памяти

Имеются три способа формирования памяти:

метод минимумов-максимумов. При выборе этого метода данные сначала разбиваются на ряд полос, количество которых определяются следующим соотношением:

$$n_b = \frac{n_m}{2p} \quad (4.1)$$

Здесь n_m – количество выбираемых векторов (размер матрицы памяти), p – число входных сигналов, n_b – число полос, на которые разбивается сигнал. На следующем и последнем этапе выбираются минимальное и максимальное значения для каждого сигнала из каждой полосы.

Этот метод разработан для облегчения использования непараметрического моделирования для наблюдения за промышленными процессами. В то время компьютеры не были достаточно мощными, чтобы оценить матрицу памяти, содержащую тысячи тренировочных точек, поэтому понадобился сокращенный

набор. Этот сокращенный набор был построен путем выбора оптимальных образцовых векторов. Оптимален он в том смысле, что содержит не более $2N$ векторов, где N — количество сигналов или точек данных в системе; и эти векторы охватывают весь диапазон, отмеченный всеми датчиками или источниками данных в течение доступного периода обучения. Всякий раз, когда два или более сигнала одновременно достигают максимума или минимума, результирующее количество обучающих векторов будет меньше $2N$.

По сути, при выборе минимального и максимального вектора p -мерный сигнал рассматриваются как совокупность n_b рабочих областей, а затем выбирается минимальное количество векторов памяти из каждой из n_b полос.

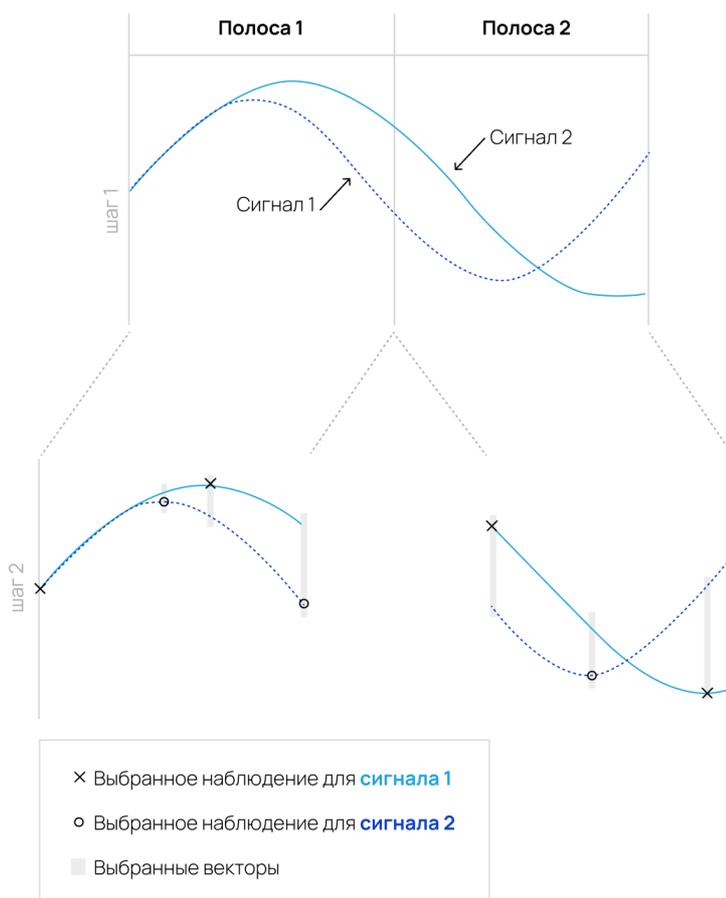


Рисунок 4.1 Иллюстрация метода минимумов-максимумов

Для ясности схема алгоритма представлена на рисунке 4.1. Этот пример демонстрирует процедуру выбора восьми векторов из двух сигналов (т. е. $n_m = 8$ и

$p = 2$). Учитывая эту информацию, соответствующее количество последовательных полос данных определяется:

$$n_b = \frac{8}{2 \times 2} = 2 \quad (4.2)$$

Это указывает на то, что данные должны быть разделены посередине; в частности, полоса 1 – это первая половина данных, а полоса 2 – вторая половина. Наконец, из этих двух полос выбираются минимальное и максимальное значения сигналов.

Важно отметить, что при выборе минимально-максимального вектора выбранные векторы гарантированно ограничивают рабочий диапазон обучающих данных, но нет гарантии, что выбранные векторы будут в достаточной степени покрывать промежуточные значения между локальными минимумами и максимумами;

метод сортировки векторов. Метод выбирает векторы, сначала упорядочивая их в соответствии с некоторыми критериями, а затем периодически отбирая упорядоченные векторы, чтобы получить определенное количество векторов (n_m). Традиционно этот метод применялся после выбора минимального и максимального векторов в рабочем диапазоне данных. В данной реализации векторы упорядочены в соответствии с их евклидовой нормой (N) в порядке возрастания (т. е. сначала наименьшее значение). Если векторы содержат p сигналов, то евклидова норма i -го вектора определяется как:

$$N_i = \sqrt{X_{i,1}^2 + X_{i,2}^2 + \dots + X_{i,p}^2} \quad (4.3)$$

Здесь X_{ij} — это i -е наблюдение j -го сигнала, а N_i — евклидова норма для i -го вектора или наблюдения p сигналов.

Евклидову норму также можно интерпретировать как расстояние i -го вектора от начала координат. Следовательно, этот метод по своей сути связан с местоположением источника и предлагается, чтобы данные были центрированы по среднему значению и масштабировались по единичной дисперсии до выбора векторов, чтобы контролировать этот эффект.

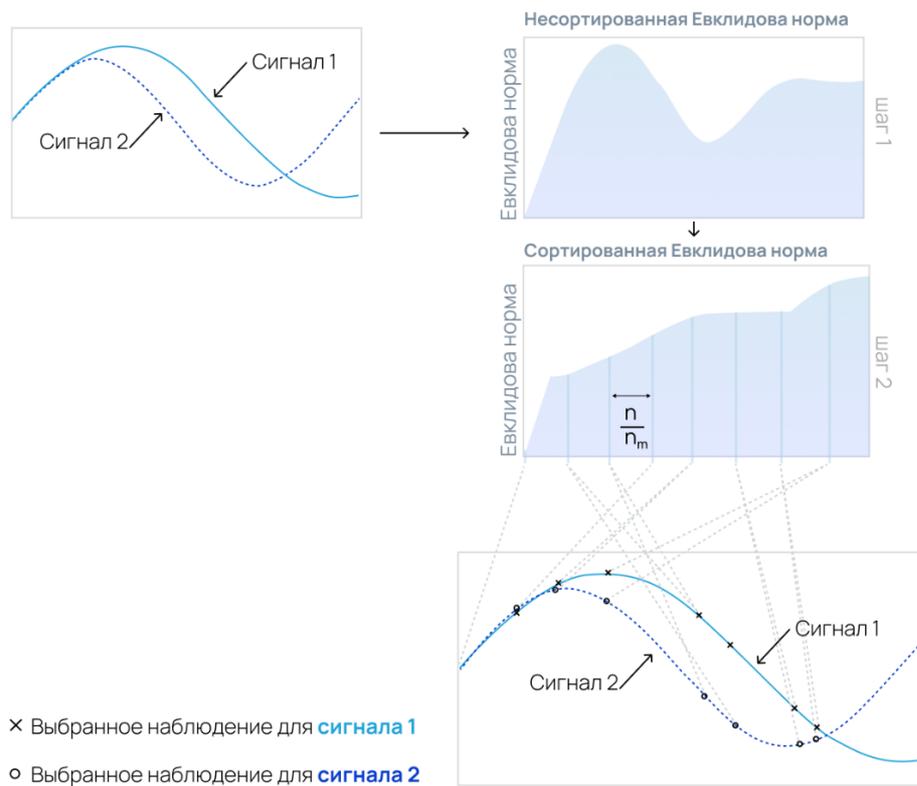


Рисунок 4.2 Иллюстрация метода сортировки векторов

Чтобы определить размер последовательных шагов выборки (n_s), нужно разделить общее количество векторов (n) на количество выбираемых векторов (n_m), то есть:

$$\Delta n_s = \frac{n}{n_m} \quad (4.4)$$

После упорядочивания образцы векторов выбираются путем выборки каждого n_s -сортированного вектора.

Для ясности схема алгоритма выбора упорядочения векторов представлена на рисунке 4.2. Этот пример демонстрирует процедуру для выбора восьми векторов из двух сигналов (т. е. $n_m = 8$ и $p = 2$). Первым шагом в процедуре отбора является расчет евклидовых норм. Далее евклидовы нормы сортируются и, наконец, периодически отбираются восемь векторов памяти. Обратите внимание, что для n наблюдений двух сигналов размер шага или количество точек между выбранными наблюдениями Δn_s равно $n/8$;

комбинированный метод. Комбинация вышеописанных методов для определения n_m векторов памяти включает в себя сначала извлечение минимального и максимального наблюдений для каждого из p сигналов, в результате чего получается не более $2p$ выбранных наблюдений. Если одно наблюдение содержит минимальное или максимальное значение для более чем одного сигнала, то это наблюдение выбирается только один раз. Затем оставшиеся векторы памяти выбираются с помощью метода сортировки векторов без замены ранее выбранных векторов.

Важно учитывать требования задачи и ограничения на ресурсы при выборе метода. В данной работе был использован комбинированный, так как он позволяет сохранить баланс между количеством выбранных векторов с сохранением максимального количества информации, то есть метод сохраняет достаточное количество информации о промежуточных значениях между максимумами и минимумами и при этом не увеличивает количество выбранных векторов до уровня, который может привести к переобучению.

4.1.3 Вычисление матрицы весов

Матрица весов представляет меру подобия между текущим вектором наблюдения и вектором истории в обучающей матрице D . Она может быть получена путем минимизации остаточного вектора

$$\varepsilon = \|X_{obs} - X_{est}\| \quad (4.5)$$

Решение наименьших квадратов для минимизации ε дает следующее выражение:

$$W = (D^T \cdot D)^{-1} \cdot (D^T \cdot X_{obs}) \quad (4.6)$$

Главным недостатком этого линейного метода является то, что линейные взаимосвязи между векторами состояний в D приводят к сингулярности матрицы $(D^T \cdot D)$. В MSET этот недостаток преодолевается за счет применения нелинейных операторов вместо умножения матрицы. Применение этих операторов позволяет избежать сингулярности матриц распознавания. MSET расширяет уравнения

множественной регрессии, чтобы включить нелинейный оператор следующим образом [106]:

$$W = (D^T \otimes D)^{-1} \cdot (D^T \otimes X_{obs}) \quad (4.7)$$

Структура оператора \otimes приведена на рисунке 4.3 [104].

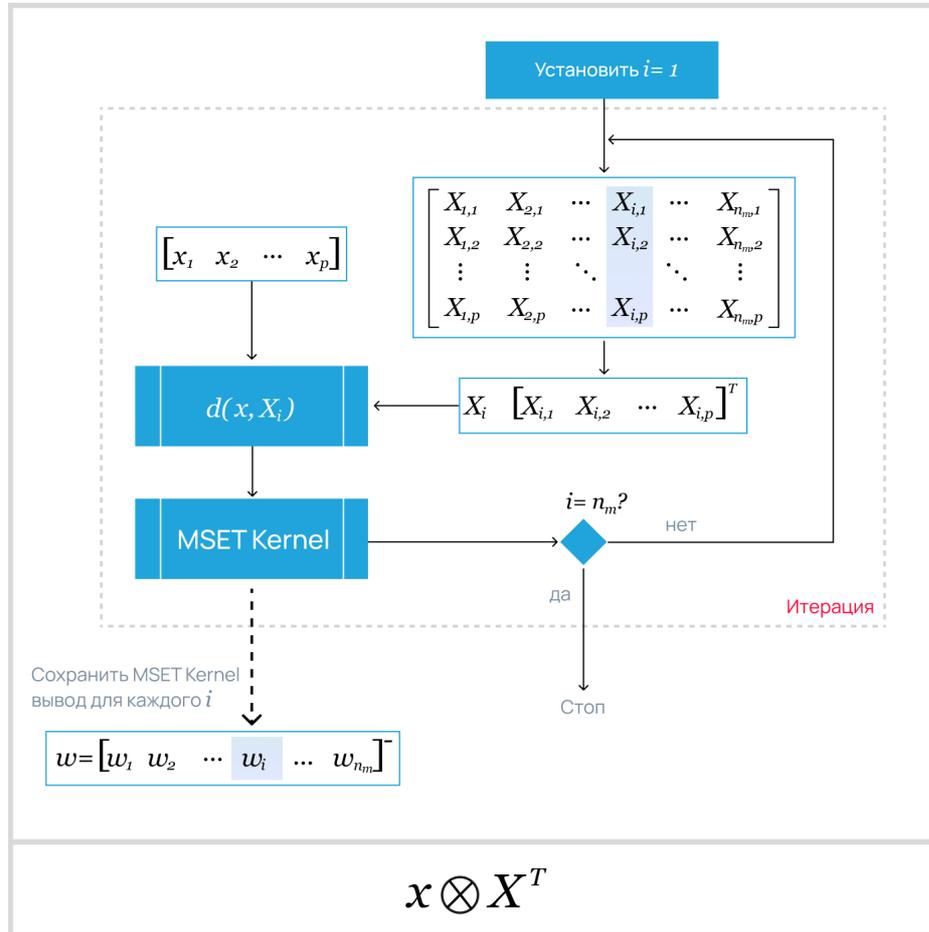


Рисунок 4.3 Структура ядерной операции

В качестве ядерного оператора был использован оператор Гаусса:

$$K_h(x, x_i) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{x-x_i}{2\sigma^2}} \quad (4.8)$$

4.1.4 Вычисление предсказания

Расчет предсказанных значений выполняется в соответствии с выражением:

$$X_{est} = D \cdot (D^T \otimes D)^{-1} \cdot (D^T \otimes X_{obs}) \quad (4.9)$$

Далее по вычисленным значениям находятся невязки $(X_{est} - X_{obs})$, на которых рассчитываются T^2 - критерии и выдвигается вердикт о состоянии наблюдаемой системы.

4.2 Вариационный автоэнкодер

Вариационные автоэнкодеры [107,108] относят к семейству генеративных моделей. На вход энкодера подаются наблюдаемые данные $x \in \mathbb{R}^{dx}$, $x \sim p(x)$, которые затем отображаются в латентное пространство $z \in \mathbb{R}^{dz}$, $z \sim p(z)$. На вход декодера подаются сгенерированные из $p(z)$ объекты.

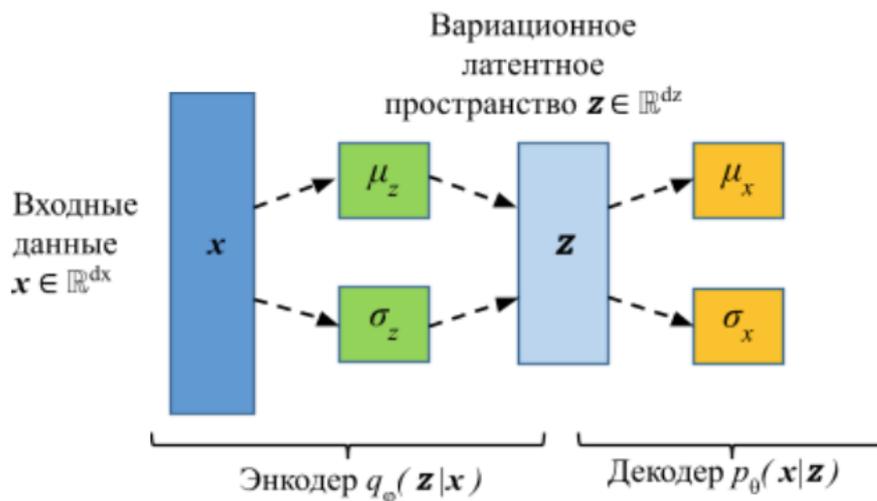


Рисунок 4.4 – Схема вариационного автоэнкодера

Таким образом, энкодер для каждого x предсказывает два значения: среднее μ и дисперсию σ нормального распределения, из которых уже генерируются значения латентной переменной z .

Пусть θ – латентный параметр ВАЭ, z – латентные переменные, а x – исходные данные [69]. Тогда:

$$p_\theta(x, z) = p_\theta(x|z) \cdot p_\theta(z) \quad (4.10)$$

где: $p_\theta(x, z)$ – совместное распределение x и z ; x – наблюдаемые исходные данные; z – латентная переменная; $p_\theta(z)$ – априорное распределение латентной переменной z ; $p_\theta(x|z)$ – вероятность наблюдения x , при заданной переменной z . Требуется получить апостериорное распределение $p_\theta(z|x)$.

Апостериорное распределение $p_\theta(z|x)$ может быть получено из соотношения:

$$p_\theta(z|x) = \frac{p_\theta(x, z)}{p_\theta(x)} \quad (4.11)$$

$$p_\theta(x) = \int p_\theta(x, z) dz = \int p_\theta(x|z) \cdot p_\theta(z) dz \quad (4.12)$$

Задача обучения ВАЭ заключается в оптимизации параметра θ так, чтобы $p_\theta(x)$ максимально приблизилось к $p(x)$. Проблема в том, что напрямую оптимизировать интеграл зачастую невозможно, поскольку распределение $p_\theta(x|z)$ может быть многомерным и сложным для вычислений. Одним из решений является идея аппроксимировать $p_\theta(x|z)$ неким распределением $q_\varphi(x|z)$ с последующей минимизацией расстояния Кульбака-Лейблера:

Параметр φ («вариационный параметр энкодера») может быть получен в процессе обучения ВАЭ. Предположим, что априорное распределение латентных переменных $p_\theta(z) = \text{Normal}(0, I)$. Тогда, если энкодер преобразует входные данные x в среднее μ_z и стандартное отклонение σ_z , параметры апостериорного распределения будут:

$$(\mu_z, \sigma_z) = \text{энкодер}_\varphi(x) = f_\varphi(x) \quad (4.13)$$

$$q_\varphi(z|x) = \text{Normal}(\mu_z, \sigma_z \cdot I) \quad (4.14)$$

Для случая нормальных распределений $q_\varphi(z|x)$ и $p_\theta(z)$, функция потерь ВАЭ может быть записана как:

$$L_{\text{ВАЭ}}(\theta, \varphi, x, \hat{x}) = \|x - \hat{x}\|^2 + \lambda \cdot D_{KL}[q_\varphi(z|x)||p_\theta(z)] \quad (4.15)$$

$$D_{KL}[q_\varphi(z|x)||p_\theta(z)] = D_{KL}[\text{Normal}(z, \mu_z, \sigma_z \cdot I)||\text{Normal}(z, 0, I)] \quad (4.16)$$

$$D_{KL}[q_\varphi(z|x)||p_\theta(z)] \cong \frac{1}{2} \sum_{j=1}^J (1 + \log(\sigma_j) - \mu_j^2 - \sigma_j) \quad (4.17)$$

$$z = \mu_z + \sigma_z \odot \varepsilon, \varepsilon \sim \text{Normal}(0, I) \quad (4.18)$$

Для обнаружения аномалий использовался вариационный автоэнкодер с вариационным вниманием (рисунок 4.5). Кроме того, используя алгоритм восстановления вероятности, на выходе декодера получаем не только сам восстановленный $x^r(t)$, а еще и параметры его нормального распределения. Это позволяет строить доверительные интервалы для восстановленных сигналов, с нормальным распределением.

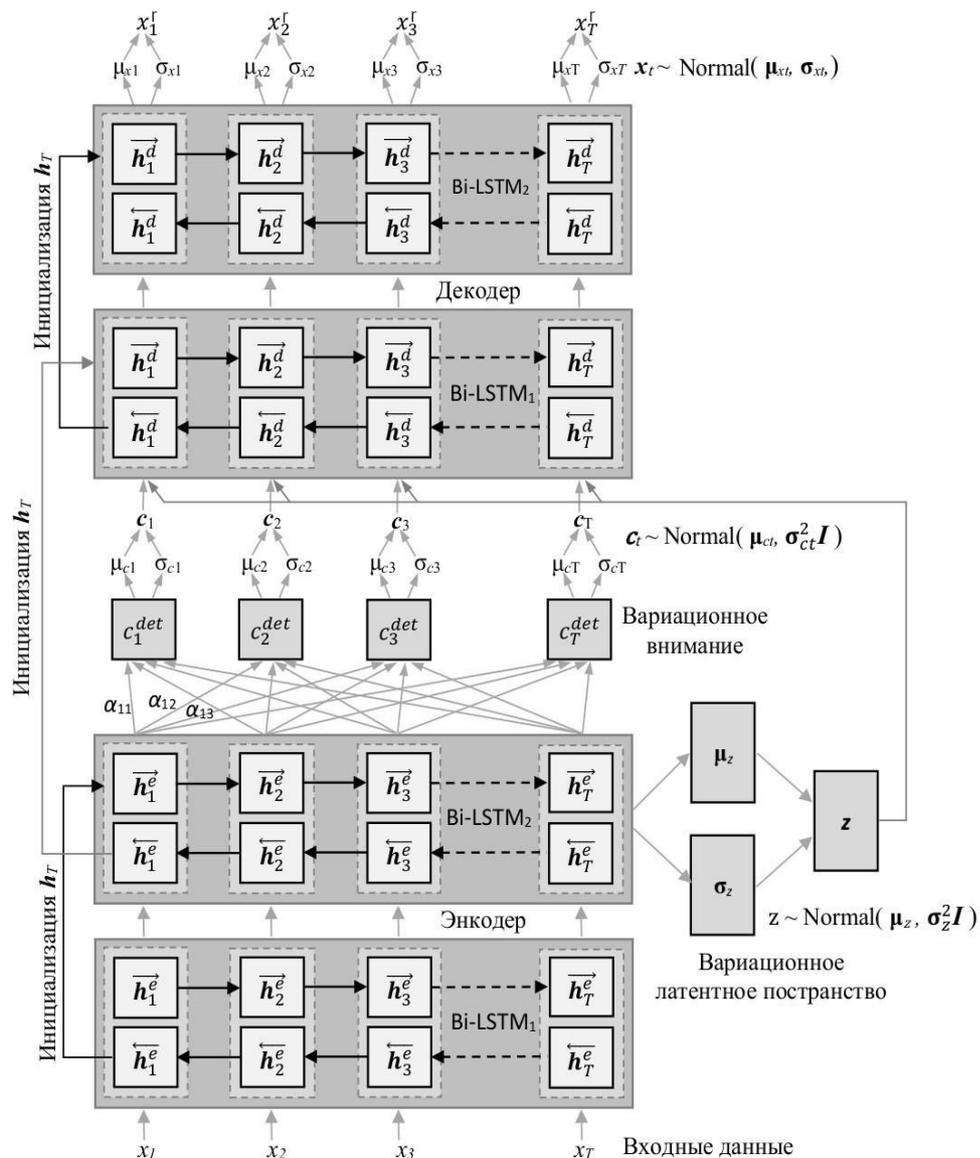


Рисунок 4.5 – Схема вариационного автоэнкодера

Обучение ВАЭ производилось путем минимизации функции потерь, методом стохастического градиентного спуска. Переменные латентного

пространства сэмплировались L раз ($L=1$ при обучении модели и $L=50$ при обнаружении аномалий).

При обучении ВАЭ для обеспечения сходимости метода градиентного спуска требуется стандартизация исходных данных. Данные были стандартизированы, т.е. приведены к среднему = 0 и дисперсии = 1 по формуле 4.19 на обучающей выборке.

$$x'' = \frac{x - \mu(x)}{\sigma(x)} \quad (4.19)$$

Полученные параметры $\mu(x)$ и $\sigma(x)$ отклонения далее применялись для тестовой выборки. Этот метод стандартизации применим в предположении, что статистика входных данных в полной мере определяется обучающей выборкой и далее не меняется.

Все отклонения от статистики обучающей выборки воспринимаются моделью как «аномалии», в том числе тренды, что можно применить при исследовании, например, ресурса оборудования на длинных временных промежутках, когда происходят медленные изменения параметров (старение). Заметим, что указанная процедура стандартизации не подходит для детектирования заведомо нестационарных (но «нормальных») процессов, например, перепада давления на ГЦН или изменения мощности ГЦН. Подобные процессы нуждаются в приведении к стационарному виду путем удаления трендов, что приводит к потере части информации.

Удаление трендов производилось в три этапа:

- сглаживание по 20 точкам исходного сигнала методом скользящего среднего;
- численное дифференцирование по трем точкам сглаженного сигнала;
- применение фильтра Савицкого-Голея.

4.3 Модель обнаружения аномалий

Обнаружение неисправностей со статистикой Хотеллинга (T^2 -критерий) [109] и статистикой квадратной ошибки прогнозирования (SPE, Q -критерий) [110] выполняется с помощью метода главных компонент. Метод главных компонент производит линейное преобразование исходных данных в набор некоррелированных переменных (главных компонент). Первый главный компонент имеет максимально возможную дисперсию, второй имеет вторую по величине дисперсию и так далее. Выбирая первые N основных компонент, можно уменьшить размерность исходных данных без потери слишком большого количества информации.

Этот метод разлагает ковариационную матрицу S исходной матрицы данных X ($n \times m$) на данные, собранные из системы в нормальных условиях эксплуатации, используя разложение по сингулярным значениям:

$$S = P\Lambda_k P^T + \tilde{P}\tilde{\Lambda}\tilde{P}^T \quad (4.20)$$

где Λ_k содержит на своей диагонали k наиболее значимых собственных значений S в порядке убывания. Их связанные собственные векторы содержатся в P . Остаточные собственные векторы и собственные значения ($m - k$) можно найти в \tilde{P} и $\tilde{\Lambda}$ соответственно.

T^2 -критерий – это многомерный аналог T -статистики Стьюдента и фактически является расстоянием Махаланобиса между вектором состояния $X_n^{1 \times D}$ и вектором средних $\mu_X^{1 \times D}$ обучающей выборки. Он позволяет оценивать текущее состояние оборудования через сравнение его параметров с заранее установленным эталонным вектором нормального функционирования. Каждое значение критерия показывает степень отклонения реальных характеристик оборудования от штатного режима работы, что дает возможность детектировать потенциальные неисправности или отклонения в работе системы.

При проведении серии однотипных экспериментов с единицей оборудования формируется эталонный вектор средних значений, который служит

базой для последующих сравнений. В случае использования в качестве базового вектора значений, связанных с предельно допустимыми или аварийными режимами, логика критерия будет построен таким образом, что его стремление к малым величинам интерпретируется как сигнал о приближении к критическому состоянию оборудования.

Нередко возможно комплексное использование критерия Хотеллинга и метода главных компонент. При этом возможно два сценария:

1. использования для анализа главных компонент с максимальной дисперсией;
2. использование для анализа остаточных компонент.

В первом случае применяется T^2 -критерий, а во втором – Q -критерий, который рассчитывается как евклидова норма вектора остаточных компонент [111,112,113]. Q -критерий выявляет тонкие отклонения в зависимостях между параметрами, которые не были учтены при первоначальном анализе главных компонент. Зарождение отклонений в Q -критерии служит индикатором потенциальных нарушений в анализируемом объекте и может указывать на зарождающуюся неисправность.

Принципиальное различие между подходами заключается в информативности: главные компоненты содержат сигналы с наибольшей дисперсией, а остаточные компоненты преимущественно представлены шумом. Вследствие этого контрольные пределы для T^2 -критерия обычно выше, чем для Q -критерия. Такая особенность означает, что для обнаружения неисправности через T^2 -критерий требуется более существенное возмущение в системе, в то время как Q -критерий способен улавливать более тонкие изменения.

Повышение эффективности анализа достигается за счет использования одновременно сразу двух критериев. Однако, у каждого из них имеются свои особенности и ограничения: Q -критерий чувствителен к изменениям взаимосвязей между контролируруемыми параметрами, а T^2 -критерий существенно зависит от характеристик эталонной выборки. Выбор правильной эталонной

выборки становится критическим фактором, влияющим на корректность работы диагностического алгоритма. Дополнительную сложность представляет задача определения оптимальных контрольных пределов для обеспечения надежного и точного обнаружения аномалий.

Оборудование находится в нормальных условиях эксплуатации для уровня значимости α , если T^2 находится ниже его порогового T_α^2 :

$$T^2 = x^T D x < T_\alpha^2 \quad (4.21)$$

где $D = P A^{-1} P^T$.

Q -критерий для нового наблюдения x учитывает нормальные условия, когда Q находится ниже порогового значения Q_α :

$$Q = x^T \tilde{C} x < Q_\alpha \quad (4.22)$$

где $\tilde{C} = \tilde{P} \tilde{\Lambda} \tilde{P}^T$.

Способ получения пороговых значений для T^2 и Q описан в [114,115]. Значение допустимого предела T_{UCL}^2 вычисляется по следующей формуле:

$$T_{UCL}^2 = \frac{R(N-1)(N+1)}{N(N-R)} \cdot F_\alpha(R, R-N), \quad (4.23)$$

где $F_\alpha(R, R-N)$ – F -распределение с R и $R-N$ степенями свободы, соответствующее доверительному интервалу α .

Допустимое значение для Q -критерия рассчитывается по формуле:

$$Q_{UCL} = \left[\frac{c_\alpha \sqrt{2\theta_2 h_0^2}}{\theta_1} + 1 + \frac{\theta_2 h_0 (h_0 - 1)}{\theta_1^2} \right], \quad (4.24)$$

где c_α – значение, соответствующее $(1-\alpha)$ верхнему процентилю из нормального распределения. θ_i определяется соотношением:

$$\theta_i = \sum_{j=k+1}^p \lambda_j^i, \quad i = 1, 2, 3, \text{ а } h_0 = 1 - \frac{2\theta_1 \theta_3}{3\theta_2^2} \quad (4.25)$$

Одним из важных достоинств критерия Хотеллинга является возможность расчета того, какой вклад каждый отдельный временной ряд вносит в общую величину T^2 -статистики. Данный подход описан в работе [116]:

$$d_i = T^2 - T_{(i)}^2, \quad (4.26)$$

где d_i – вклад i -го сигнала в суммарную T^2 -статистику, а $T_{(i)}^2$ рассчитывается с помощью обратной ковариационной матрицы A^{-1} с нулевыми значениями для i -го сигнала.

4.4 Результаты использования разработанного метода для анализа работы ГЦН

Проведен поиск отклонений состояния для четырех ГЦН НВАЭС-2 от начала третьей компании (03.07.2019 г.) до начала 2020 г [117]. Как видно из рис. 4.6, за это время был один сброс мощности до 80% (с 17 по 23.11.2019 г.) и один останов реактора (с 29.11.2019 г. по 04.12.2019 г.). В расчетах эти периоды компании не учитывались (пропуски данных на рисунках ниже).

В расчетах учитывалось по 49 параметров для каждого ГЦН, полученных из системы верхнего блочного уровня (СВБУ). Сюда входят вибрационные (виброперемещения), электрические (ток и мощность ГЦН) и технологические (температура, давление, расход) параметры. Проведена предварительная предобработка данных, описанная выше, для приведения всех временных рядов к единому масштабу.

Рассмотрим конкретный пример применения разработанного подхода к ГЦН-1. В качестве обучающей выборки был выбран период с 01.08.2019 г. по 30.09.2019 г. Здесь надо отметить, что никаких аномалий в работе ГЦН в 2019 г. отмечено не было и теоретически все рассматриваемые данные являются нормальными, но надо было показать, как предложенный подход отслеживает отклонения от того режима работы ГЦН, который мы определили «нормальным» – от режима, определяемого обучающей выборкой. Естественно, в реальных условиях обучение алгоритмов будет производиться на всех режимах работы ГЦН, которые считаются нормальными. Эти режимы будут представлять собой некие кластеры в пространстве состояний работы оборудования. В этом случае

аномалией будет считаться любой выход параметров работы оборудования за рамки этих кластеров.

Здесь надо отметить, что некоторые из участвующих в рассмотрении временных рядов не являются стационарными по физическим причинам. Это, например, активная мощность ГЦН и перепад давления на нем. Нестационарность этих величин обусловлена изменением концентрации бора в воде на протяжении кампании (см. рис. 4.6) и, как следствие, изменением плотности воды. Однако, стандартизация данных работает таким образом, что при обнаружении аномалий любые тренды рано или поздно приводят к выходу за пределы статистики обучающей выборки, поэтому эти ряды дифференцируются по времени и уже затем стандартизируются. Естественно, для сравнения с исходными величинами к рассчитанным параметрам должна быть применена обратная процедура (интегрирование).

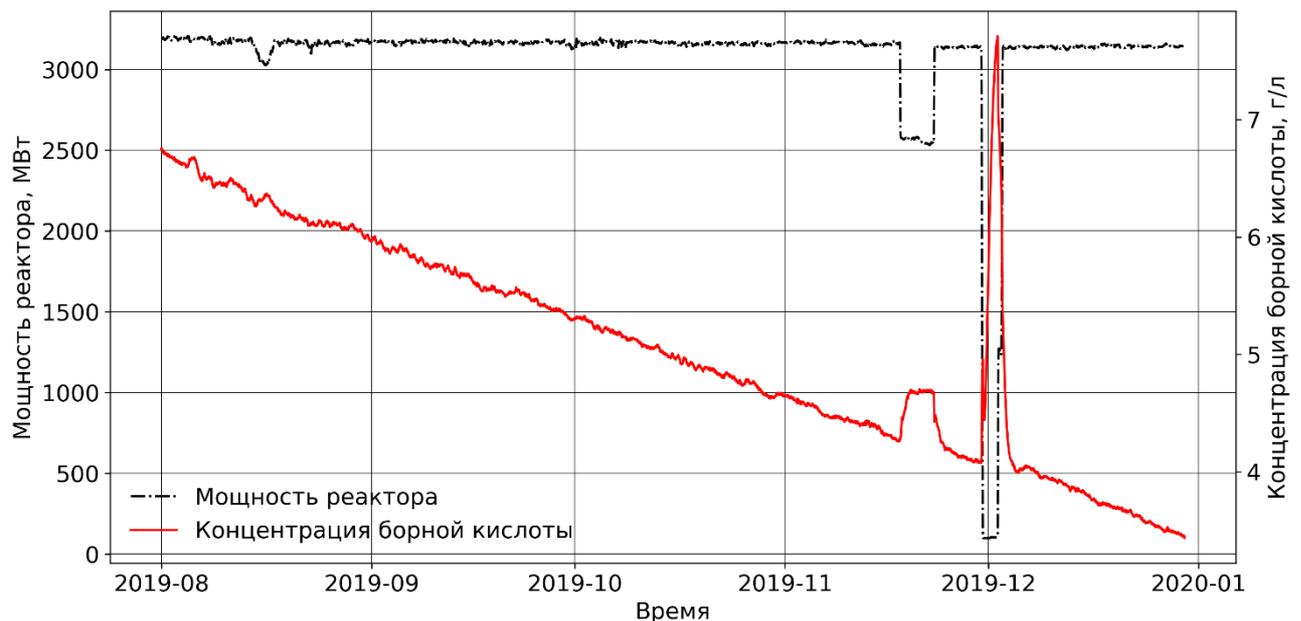
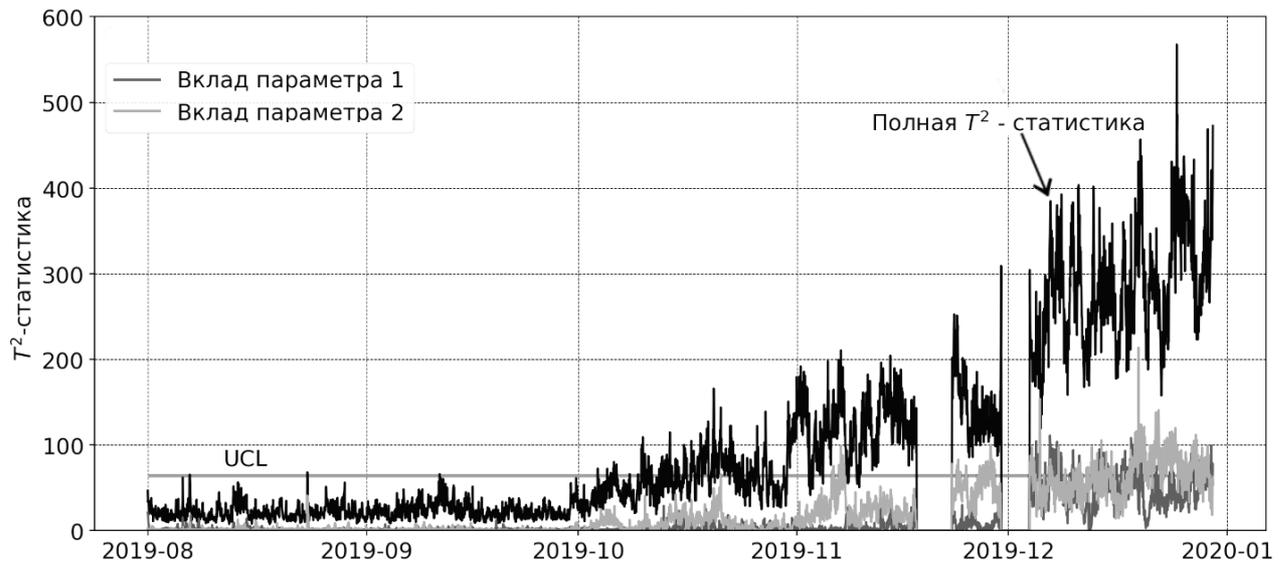


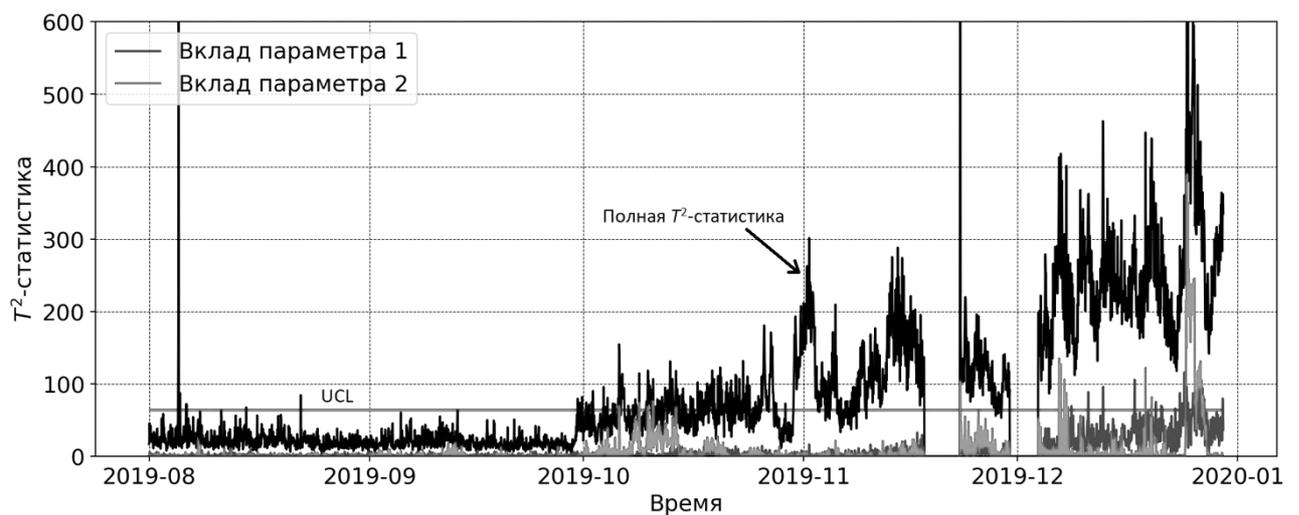
Рисунок 4.6 – Мощность реактора и концентрация борной кислоты

На рисунках 4.7 и 4.8 приведена T^2 -статистика по ГЦН-1, рассчитанная на невязках, полученных моделями ВАЭ и MSET соответственно, а также T^2 -статистика для двух основных параметров, которые вносят наибольший вклад в эту статистику.

Видно, что обе модели показали хорошую чувствительность к малейшим изменениям нормированных невязок, в случае ВАЭ вклад параметров более явный, что говорит о его большей чувствительности к изменению состояния оборудования. Поэтому данный подход может быть полезен как при выявлении аномалий в работе оборудования, так и в расчете его ресурсных характеристик.



1 – ток на электромагните; 2 – температура слива на уплотнении ГЦН-1
Рисунок 4.7 – ВАЭ: T^2 -статистика по ГЦН-1 и вклад основных параметров



1 – ток на электромагните; 2 – температура слива на уплотнении ГЦН-1
Рисунок 4.8 – MSET: T^2 -статистика по ГЦН-1 и вклад основных параметров

Метод определения аномалий в работе оборудования с использованием предложенных моделей является весьма эффективным, что продемонстрировано

на примере описания режимов работы ГЦН НВАЭС. Предлагаемые новые многомерные предиктивные характеристики могут быть также использованы для оценки остаточного ресурса оборудования.

4.5 Дополнение для ВАЭ

Так как в ВАЭ используется алгоритм восстановления вероятности, который позволяет получить на выходе не только восстановленные сигналы, но и их распределения, это позволяет строить доверительные интервалы, с помощью которых можно определить, какой конкретно временной ряд «аномален». Поэтому в случае ВАЭ дополнительно для оценки наличия аномалии использовался трехшаговый алгоритм:

- для каждой точки ряда $\mathbf{x}(t)$ из обученного декодера извлекалось среднеквадратичное отклонение $\sigma_{\mathbf{x}(t)}$;

- в каждой точке ряда $\mathbf{x}(t)$, согласно правилу «трех сигм», строились доверительные границы: нижняя $\mathbf{lower}(t) = \mathbf{x}'(t) - 3\sigma_{\mathbf{x}(t)}$ и верхняя $\mathbf{upper}(t) = \mathbf{x}'(t) + 3\sigma_{\mathbf{x}(t)}$;

- значение ряда $\mathbf{x}(t_0)$ в точке считается аномалией, если $\mathbf{x}(t_0) < \mathbf{lower}(t_0)$ или $\mathbf{x}(t_0) > \mathbf{upper}(t_0)$.

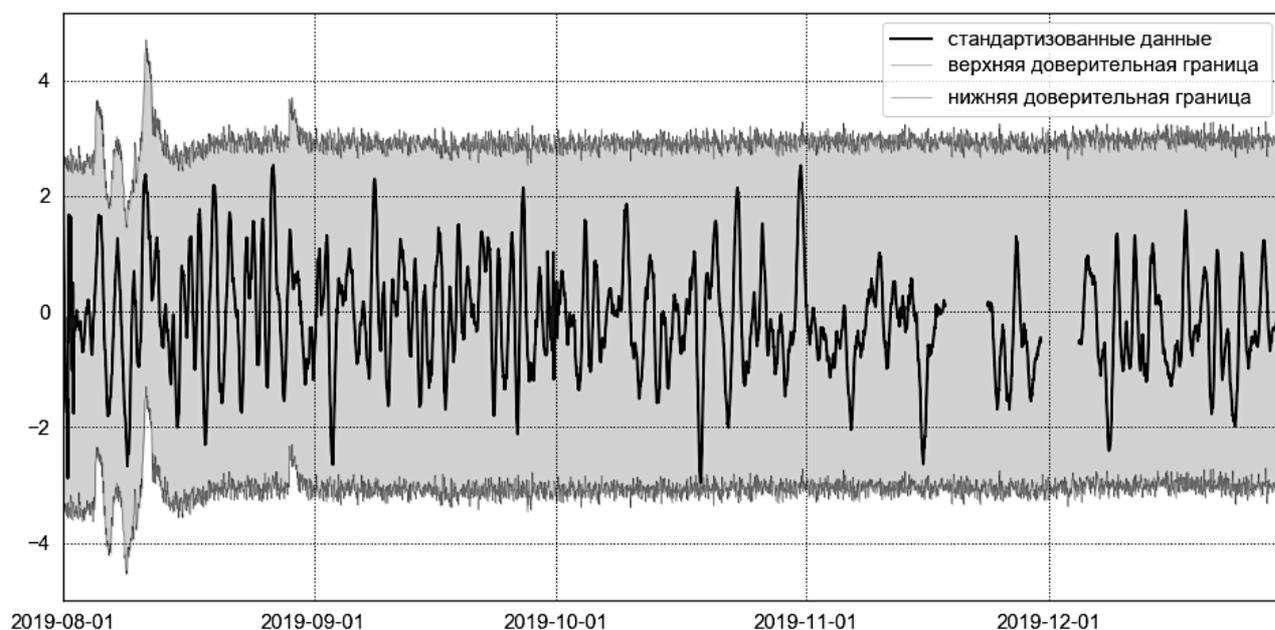


Рисунок 4.9 – Доверительные границы и активная мощность ГЦН-1 (удаление тренда)

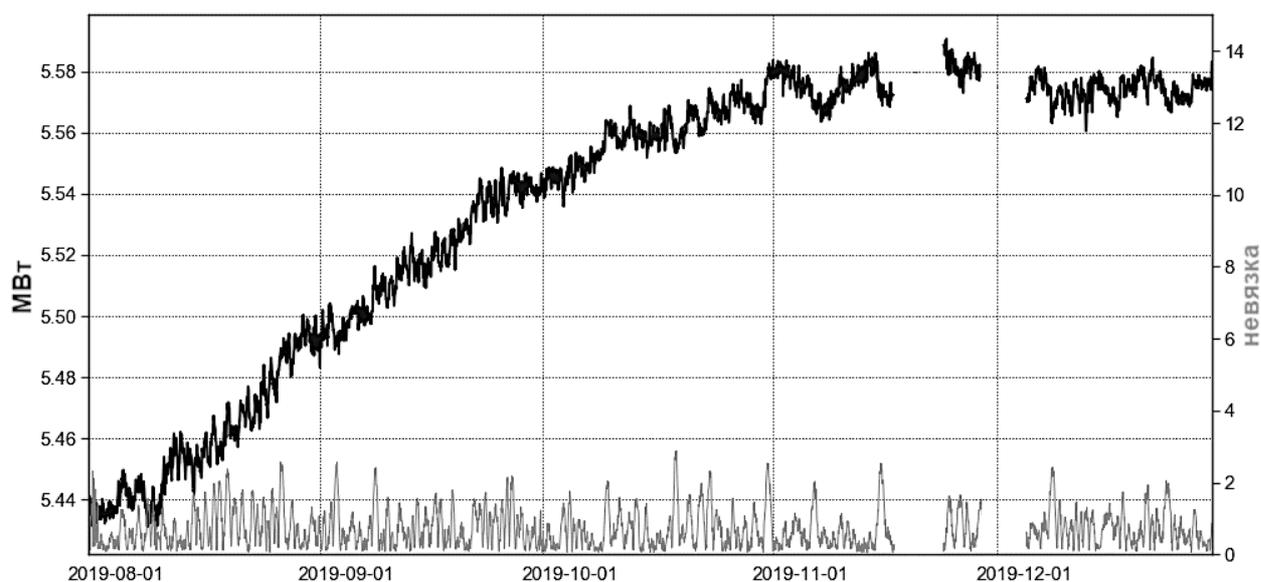


Рисунок 4.10 – Активная мощность ГЦН-1 и невязка ВАЭ (черный и серый графики соответственно)

Из рисунка 4.9 видно, что на всем протяжении рассматриваемой кампании этот сигнал находится в пределах доверительного интервала. На рисунке 4.10 приведен сам сигнал и рассчитанная с помощью ВАЭ невязка, которая в данном случае постоянна на всем рассматриваемом интервале.

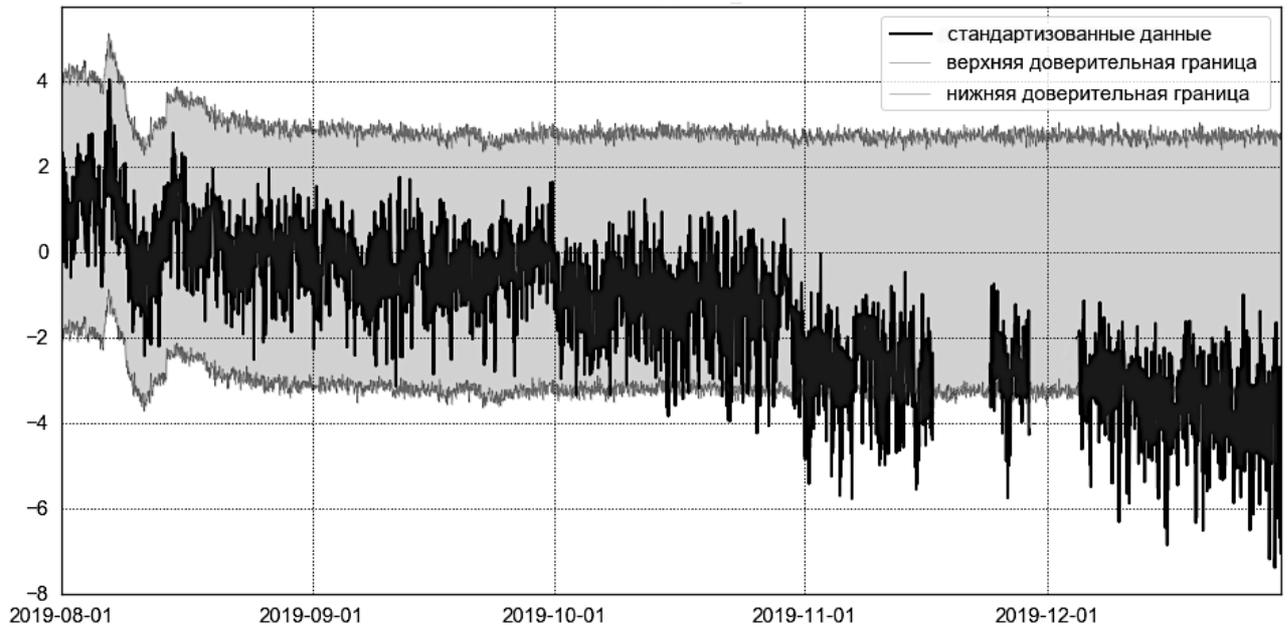


Рисунок 4.11 – Доверительные границы сигнала расхода на сливе уплотнения ГЦН-1. Виден тренд, который после 01.11.2019 будет детектирован как «аномалия» (выход за доверительные границы)

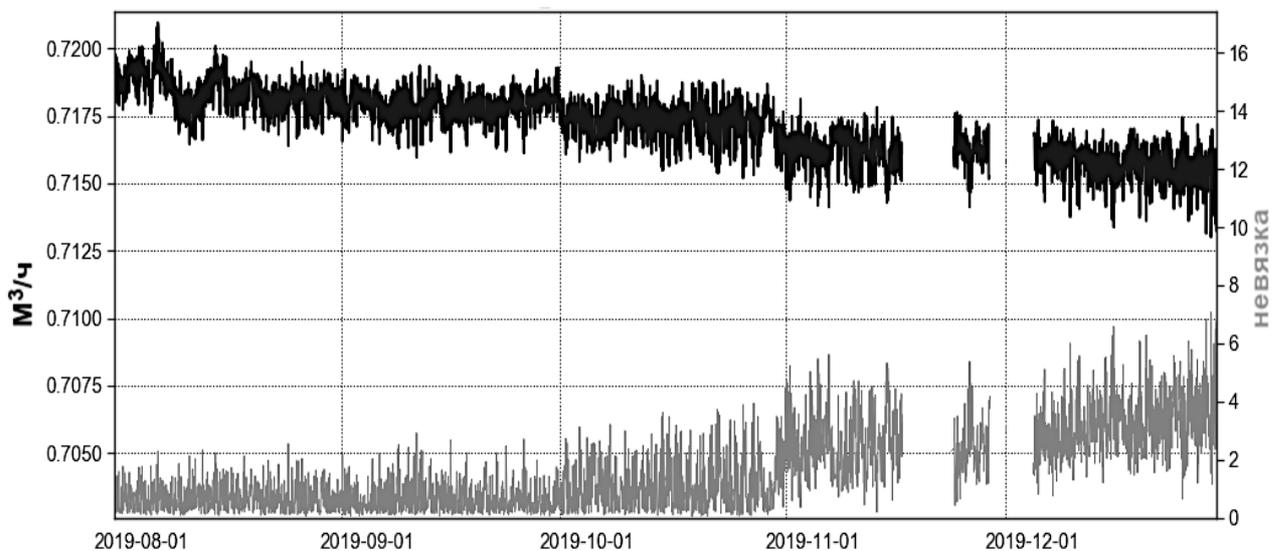


Рисунок 4.12 – Сигнал расхода на сливе уплотнения ГЦН-1 и невязка ВАЭ. (Невязка показывает наличие тренда)

Совершенно другая картина наблюдается с сигналом расхода на сливе уплотнения ГЦН-1. Сигнал находится в пределах доверительного интервала только до ноября 2019 г., а затем покидает его (рис. 4.11). Из рисунка 4.12 видно, что невязка с 01.11.2019 г. имеет устойчивый тренд.

Таким образом, обнаружение аномалий при помощи ВАЭ позволяет выделять устойчивые тренды в изменении параметров работы элементов оборудования ГЦН.

4.6 Выводы к главе 4

Разработан метод обнаружения аномалий в работе оборудования АЭС, который состоит из двух основных компонентов: модели оценки состояния и модели обнаружения неисправностей. В качестве модели оценки состояния в рамках работы были рассмотрены две многомерные модели:

– вариационный автоэнкодер с механизмом внимания на основе двунаправленных рекуррентных сетей. Он используется для извлечения признаков из данных различного типа датчиков, что позволяет получить компактное представление сигналов и упрощает дальнейшую обработку и анализ;

– многомерный метод оценки состояния (MSET) – использует показания датчиков, характеризующих нормальное рабочее состояние системы, для изучения корреляций между этими сигналами (на этапе обучения) и получения точной оценки каким «должен быть» каждый сигнал, на основе последнего набора показаний датчиков и ранее изученных корреляций между ними (на этапе прогнозирования).

Модель обнаружения неисправностей, использующая критерий Хотеллинга для анализа остаточных временных рядов, полученных путем вычитания каждого измеренного сигнала из его численно сгенерированного аналога, определяет, является ли процесс нормальным или аномальным.

Преимуществом использования данного критерия является возможность определения покомпонентного вклада каждого отдельного временного ряда в суммарную статистику и дальнейшая локализация неисправности на основе определения сигналов, внесших наибольший вклад в ее развитие, что в свою

очередь, поможет эксперту определить истинную причину неисправности оборудования.

Эффективность разработанных алгоритмов демонстрируется на примере работы ГЦН блока № 1 Нововоронежской АЭС-2. Алгоритмы демонстрируют высокую чувствительность к изменению режимов ГЦН и определению неполадок в работе, а также позволяют следить за их работой как в онлайн, так и в офлайн режимах. В процессе исследования были использованы данные различных типов датчиков, таких как: вибрационные, температур и давления. На основании этих данных разработаны критерии диагностирования, которые позволяют выявлять аномалии в работе оборудования и принимать меры по их устранению.

Разработан программный модуль, который позволил реализовать предложенный алгоритм на практике. Данный модуль может быть использован для диагностирования оборудования АЭС, что поможет повысить их надежность и безопасность эксплуатации.

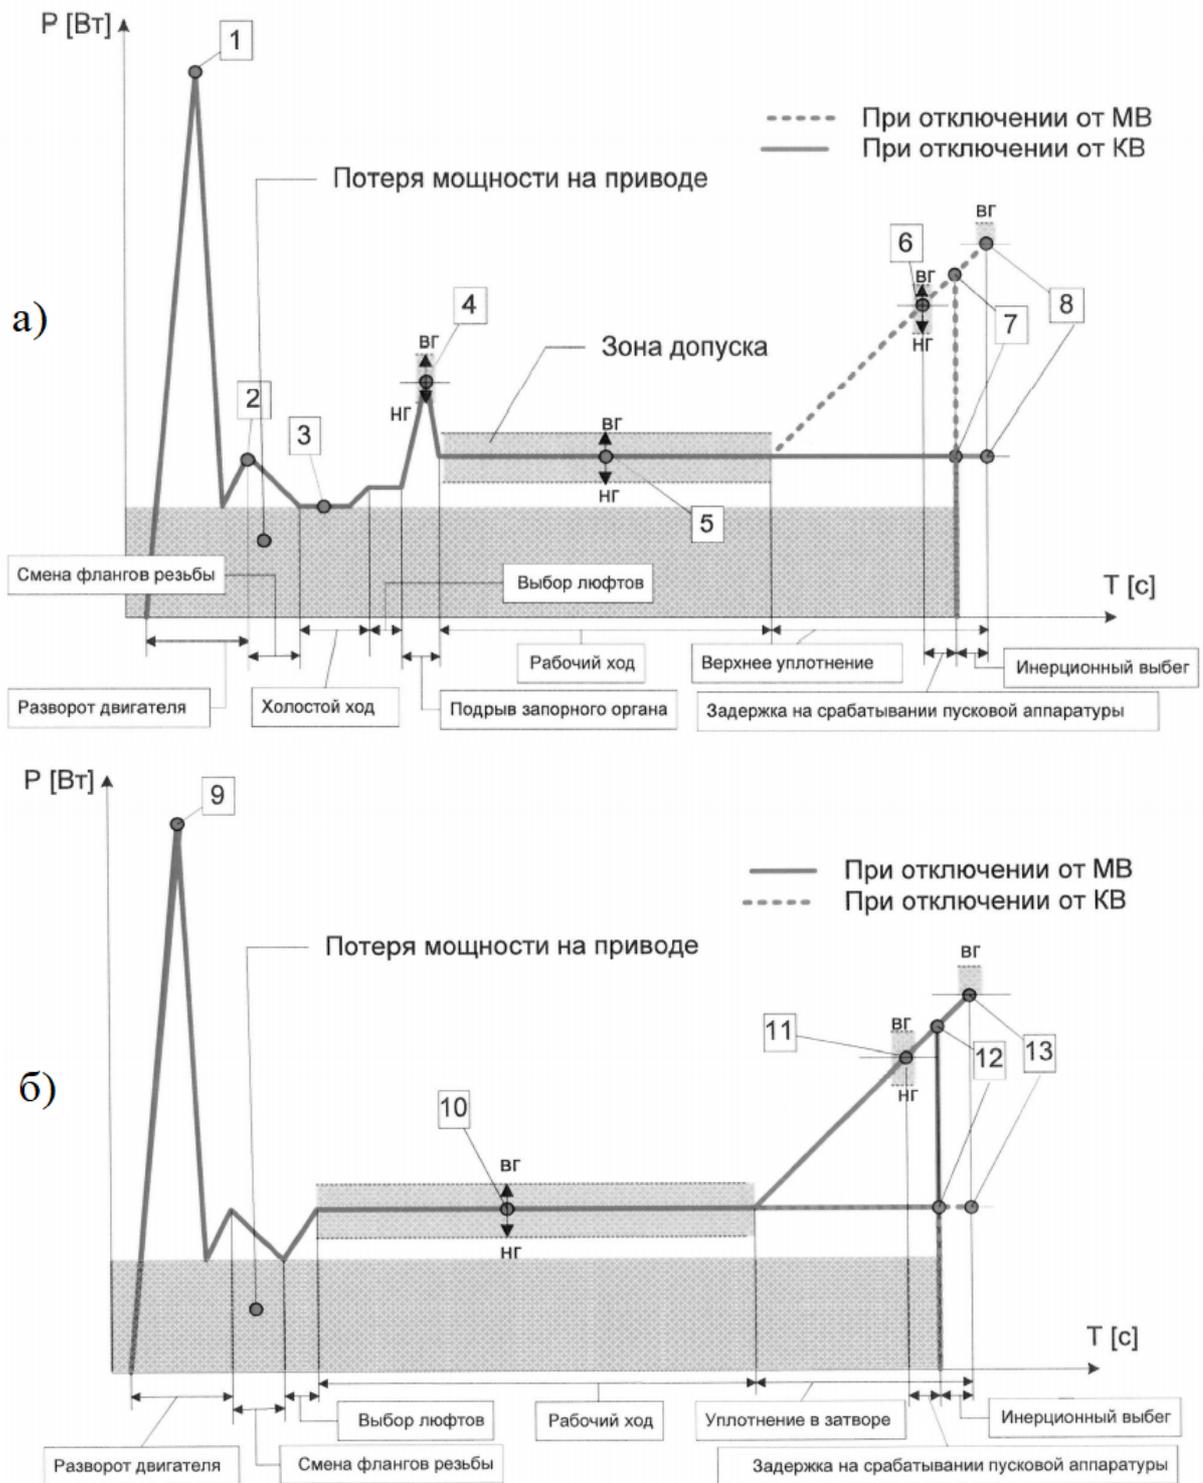
Глава 5. Автоматическая сегментация сигналов электроприводной арматуры сверточной нейронной сетью

Одним из самых многочисленных классов оборудования на АЭС является электроприводная арматура (ЭПА). Важной проблемой диагностирования ЭПА является оперативный (онлайн) автоматизированный контроль технического состояния ЭПА при работе энергоблока на мощности. В связи с этим актуальной является задача диагностирования ЭПА по сигналам тока и напряжения, потребляемым в процессе выполнения операций «открытие» и «закрытие» ЭПА. Сигналы тока и напряжения представляют собой временные ряды, измеренные через равные промежутки времени. Сигналы тока (и напряжения) могут быть получены в онлайн-режиме и содержат всю необходимую информацию для оперативной диагностики ЭПА.

Суть подхода состоит в том, что по сигналам тока и напряжения рассчитываются сигналы активной мощности. Далее из определенных участков (сегментов) сигналов активной мощности извлекаются характеристики («диагностические признаки»), по значениям которых и диагностируется ЭПА. Для автоматизации сегментирования сигналов активной мощности разработан алгоритм, основанный на использовании сверточной нейронной сети [118]. Разбиение временного ряда на внутренне однородные сегменты важная задача интеллектуального анализа данных, так как позволяет выделять из больших объемов информации ключевые характеристики временного ряда в более компактной форме [119].

Примерами таких временных рядов являются сигналы активной мощности ЭПА при выполнении операций «открытие» и «закрытие». Диагностика заключается в разбиении сигналов на сегменты и дальнейшем выделении из каждого сегмента «диагностических признаков» (численных величин, по которым делаются выводы об исправности или неисправности ЭПА) [120]. Каждый

сегмент отвечает за срабатывание определенных узлов и элементов ЭПА и имеет характерные особенности.



а) открытие задвижки, б) закрытие задвижки (МВ и КВ – моментный и концевой выключатель соответственно)

Рисунок 5.1 – Характерные точки сигнала активной мощности

5.1 Постановка задачи

На данный момент в большинстве систем диагностики ЭПА подобное разбиение производится вручную, что занимает большое время и не позволяет перевести диагностику в автоматический режим. Для решения этой проблемы предложена глубокая нейронная сеть, автоматически сегментирующая сигнал активной мощности. В соответствии с методологией [121], диагностика ЭПА производится по набору численных значений в характерных точках и на определенных временных интервалах сигнала активной мощности в цикле срабатывания ЭПА. На рис. 5.1 характерные точки выбраны с учетом факторов, влияющих на техническое состояние ЭПА и, тем самым, на изменения сигнала активной мощности, и исходя из периодов движения запорного элемента арматуры (рис. 5.1). В [122] было показано, что искусственные нейронные сети хорошо справляются с задачей сегментации временных рядов.

5.2 Подготовка исходных данных

Для расчета сигнала активной мощности использовались электрические параметры тока и напряжения со статорных обмоток электродвигателя ЭПА (по трем фазам). Активная мощность, по определению, рассчитывалась по формуле:

$$P(t) = \frac{1}{T} \cdot \int_t^{t+T} u(\tau) \cdot i(\tau) d\tau, \quad (5.1)$$

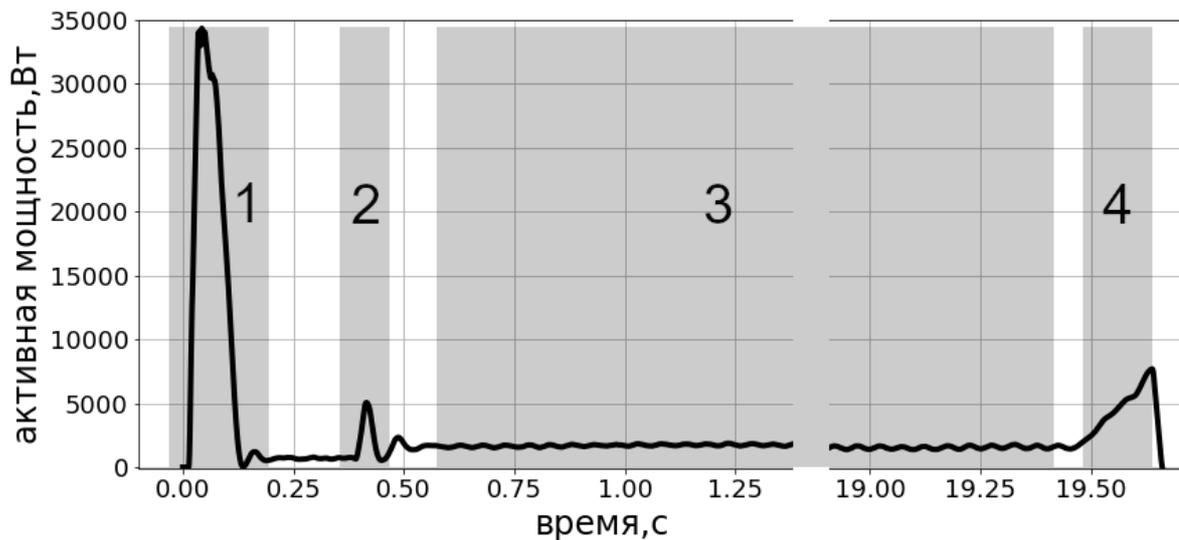
где T – период несущей частоты (50 Гц); $u(\tau)$, $i(\tau)$ – значения напряжения и тока в момент времени τ , соответственно.

5.3 Определение временных сегментов для обучение нейронной сети

Для обучения нейронной сети были выбраны следующие временные интервалы:

- 1) разворот двигателя,
- 2) подрыв запорного органа (для сигналов в ходе на открытие),
- 3) рабочий ход,
- 4) уплотнение в затворе (для сигналов в ходе на закрытия).

Таким образом, результатом сегментации является разбиение сигнала активной мощности на четыре интервала, как показано на рис. 5.2.



- 1 – старт/разворот двигателя; 2 – подрыв запорного органа (для «открытия»);
3 – рабочий ход; 4 – уплотнение (для «закрытия»)

Рисунок 5.2 – Сегментация сигнала активной мощности

Для обучения сети имеющиеся сигналы активной мощности были объединены в одномерный массив и нарезаны на отрезки длиной 10^5 точек. Данные отрезки размечались в интерактивном режиме с помощью кода, написанного на языке Python, где каждой точке в сигнале выставлялся соответствующий класс. Далее с помощью One hot кодирования создавался целевой вектор. Этот кодировщик берёт столбец с категориальными данными и создаёт для него несколько новых столбцов. Числа заменяются на единицы и

нули, в зависимости от того, какому столбцу какое значение присуще. В нашем случае получено пять столбцов, которые обозначают:

- 4 сегмента, представленные на рис. 5.2, с меткой от 1 до 4, соответствующей номеру сегмента, и окрашенные в серый цвет;
- один сегмент с меткой «no_label» – оставшиеся участки сигнала, не представляющие интерес для анализа и не имеющие окраски на рис. 5.2.

В итоге, исходные данные представлены набором, состоящим из 571 отрезков равной длины и соответствующих им масок с обозначением каждого пикселя в сигнале как принадлежащего классу (сегменту) на рис. 5.2.

Для лучшего понимания в таблице 5.1 приведена информация по размеченным сегментам, их количеству и соотношению сегментов.

Таблица 5.1 – Информация по сегментам

Название сегмента	Revers	Podriv	Flat	Stop	no_label
Соответствующий временной интервал	Пуск/разворот двигателя	Подрыв запорного органа	Рабочий ход	Уплотнение запорного органа	Участки сигнала, не рассматриваемые в анализе
Соотношение пикселей, %	0.69	0.68	95.93	0.38	2.32
Количество сегментов во всей выборке	333	121	330	137	838
Объем выборки	571				

5.4 Описание архитектуры сети

За основу была принята U-Net сеть, предложенная в [122], созданная в 2015 году для сегментации биомедицинских изображений. Архитектура сети представляет собой свёрточную сеть, модифицированную так, чтобы она могла

работать с меньшим количеством примеров (обучающих образов) и делать более точную сегментацию.

Сеть состоит из последовательно соединенных энкодера и декодера. Энкодер отвечает за захват различных признаков в разных масштабах, а декодер использует эти признаки для построения окончательной карты сегментации.

Отличительной особенностью данной модели являются skip-connections – элементы, которые соединяют части декодера и энкодера в каждом масштабе. То есть для того, чтобы передать на вход декодера тензор, конкатенируется симметричный выход с энкодера и выход предыдущего слоя декодера. Эти слои позволяют повторно использовать карты признаков из любого масштаба в декодере, что приводит к улучшению детализации сегментации.

Также после всех сверточных слоев добавлена batch-нормализация, что улучшает процесс сходимости и скорости обучения. Кроме того, она помогает контролировать веса сети, поскольку их значения всегда сохраняются в пределах нормированных значений.

5.5 Подбор и анализ функций потерь

Как следует из таблицы 5.1, в данных явно прослеживается несбалансированность классов. Дисбаланс данных является распространенной проблемой в задачах машинного обучения, таких как сегментация и классификация. В такой ситуации высока вероятность того, что классификатор будет демонстрировать искаженную производительность в пользу наиболее представленных классов. Для решения этой проблемы и достижения наилучшего качества сегментации было проведено исследование различных функций потерь. Наиболее часто используемая функция потерь для задачи сегментации изображений — это кросс-энтропийная потеря. Эта потеря исследует каждый пиксель индивидуально, сравнивая предсказания класса с заданным целевым вектором.

Поскольку кросс-энтропийная потеря оценивает предсказания класса для каждого пиксельного вектора индивидуально, а затем усредняет по всем пикселям, мы, по сути, утверждаем, что обучение каждого пикселя в изображении одинаково. В статье [123] предлагают взвешивание этой потери для каждого выходного канала, чтобы противодействовать дисбалансу классов, присутствующему в наборе данных. Формула для взвешенной по классам категориальной кросс-энтропии записывается следующим образом:

$$WCE = -\frac{1}{N} \cdot \sum_i \omega_i \sum_j y_{ij} \log p_{ij}, \quad (5.2)$$

где N – число классов, y – истинное значение класса, которому принадлежит пиксель, p – предсказанное значение класса для пикселя.

Между тем, Ronneberger в статье [122] обсуждает схему взвешивания потерь для каждого пикселя, чтобы у границ сегментированных объектов был больший вес. Эта схема взвешивания потерь помогла их модели U-Net сегментировать клетки в биомедицинских изображениях прерывистым образом, так что отдельные клетки могут быть легко идентифицированы в бинарной карте сегментации.

Таким образом, объединяя изложенные выше решения, итоговая формула для категориальной кросс-энтропии принимает вид:

$$PWCE = -\frac{1}{N} \cdot \sum_i \sum_j (\omega_i + \tilde{\omega}_{ij}) y_{ij} \log p_{ij} \quad (5.3)$$

$$\omega_i = \lg \left(\frac{n-n_i}{n_i} \right), \quad \tilde{\omega}_{ij} = \omega_0 \exp \left(-\frac{d_{ij}^2}{2\sigma^2} \right), \quad (5.4)$$

где ω – вес класса, который был рассчитан по формуле, предложенной в [124], n_i – количество элементов в i -ом классе, n – общее количество элементов, d – расстояние до ближайшей границы, ω_{ij} – вес пикселя, ω_0, σ – настраиваемые параметры.

С помощью этой стратегии можно контролировать результаты сегментации как на уровне класса, так и на уровне пикселей, настраивая функцию потерь для

конкретной задачи. На рис. 5.3 показано, как выглядят веса пикселей, рассчитанные по приведенной выше формуле.

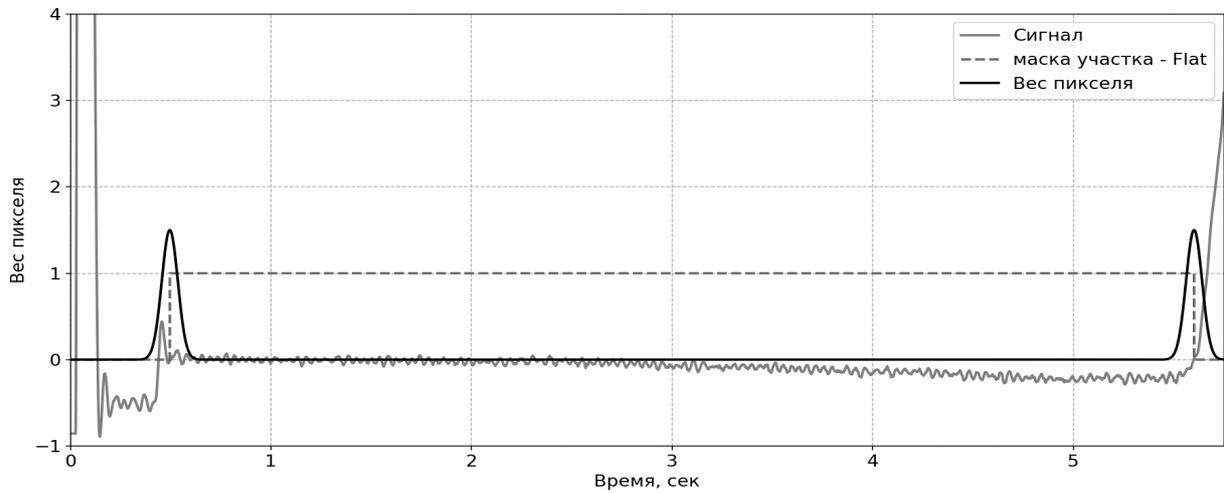


Рисунок 5.3 – График весов пикселей

В качестве функции потерь рассмотрен также Dice-коэффициент, который был описан в [124] и впервые представлен в статье [125]. Эта функция хорошо показала себя при решении задач семантической сегментации с чрезвычайно несбалансированными классами. Она принимает значения в диапазоне от 0 до 1, где значение равное 1, означает идеальное и полное перекрытие. Dice-коэффициент был первоначально разработан для двоичных данных и может быть рассчитан как:

$$Dice = \frac{2|A \cap B|}{|A| + |B|} \quad (5.5)$$

Здесь в числителе записан удвоенный набор общих элементов между наборами A и B , а в знаменателе сумма – количество элементов в этих наборах. В случае оценки Dice-коэффициента на предсказанных масках сегментации можно аппроксимировать $|A \cap B|$ как поэлементное умножение между прогнозом и целевой маской, а затем суммировать полученную матрицу.

Поскольку целевая маска для каждого класса является двоичной, эффективно обнуляются все пиксели из нашего прогноза, которые не «активированы» в целевой маске. Для остальных пикселей, по существу, штрафуются прогнозы с низкой достоверностью; более высокое значение этого

выражения, которое находится в числителе, приводят к лучшему Dice-коэффициенту.

Для количественной оценки $|A|$, а также $|B|$, некоторые исследователи [126] используют простую сумму, тогда как другие [124] предпочитают использовать для этого вычисления сумму квадратов. В данной работе предпочтение было отдано сумме квадратов, так как эта функция потерь отличилась лучшей сходимостью. Исходя из этого, формула для расчёта Dice-коэффициента принимает вид:

$$Dice = \frac{2 \sum_i y_i \cdot p_i}{\sum_i y_i^2 + \sum_i p_i^2}, \quad (5.6)$$

где y_i и p_i – истинная и предсказанная вероятность принадлежности классу.

Тогда функция потерь принимает вид:

$$Dice_loss = 1 - Dice \quad (5.7)$$

Что касается выходных данных нейронной сети, числитель рассматривает общие активации между прогнозом и целевой маской, тогда как знаменатель учитывает количество активаций в каждой маске отдельно. Это приводит к нормализации потерь в соответствии с размером целевой маски. Так что потеря Dice не препятствует обучению классов с меньшим пространственным представлением во входных данных.

5.6 Метрика оценки качества нейронной сети

В качестве метрики для оценки качества модели была использована функция «пересечение над объединением» (Intersection Over Union – IoU), также известная как индекс Жаккарда. Она является одним из наиболее часто используемых показателей в семантической сегментации. IoU — это область перекрытия между прогнозируемой сегментацией и истиной, разделенная на область объединения между прогнозируемой сегментацией и истинной. Этот показатель находится в диапазоне 0 – 1 (0 – 100%), где 0 означает отсутствие

перекрытия, а 1 означает полное перекрытие сегментации. Для мультиклассовой сегментации среднее значение IoU вычисляется путем взятия IoU каждого класса и их усреднения.

Формула для определения коэффициента IoU схожа с Dice-коэффициентом, но отличается знаменателем и выглядит следующим образом:

$$IoU = \frac{|A \cap B|}{|A \cup B|} \quad (5.8)$$

где $|A \cap B|$ – пересечение объектов A и B , $|A \cup B|$ – их объединение, как следует из названия.

5.7 Обучение нейронной сети и анализ результатов

Оптимизация сети производилась с фиксированным набором гиперпараметров для всех тестов. В качестве оптимизатора был выбран алгоритм Adam [127] с размером партии 20, скоростью обучения – 0.001. Каждый раз скорость обучения снижалась на 20% после 10 эпох без улучшения.

Далее на графиках приведены результаты обучения сети на тренировочной и валидационной выборках с использованием различных функций потерь.

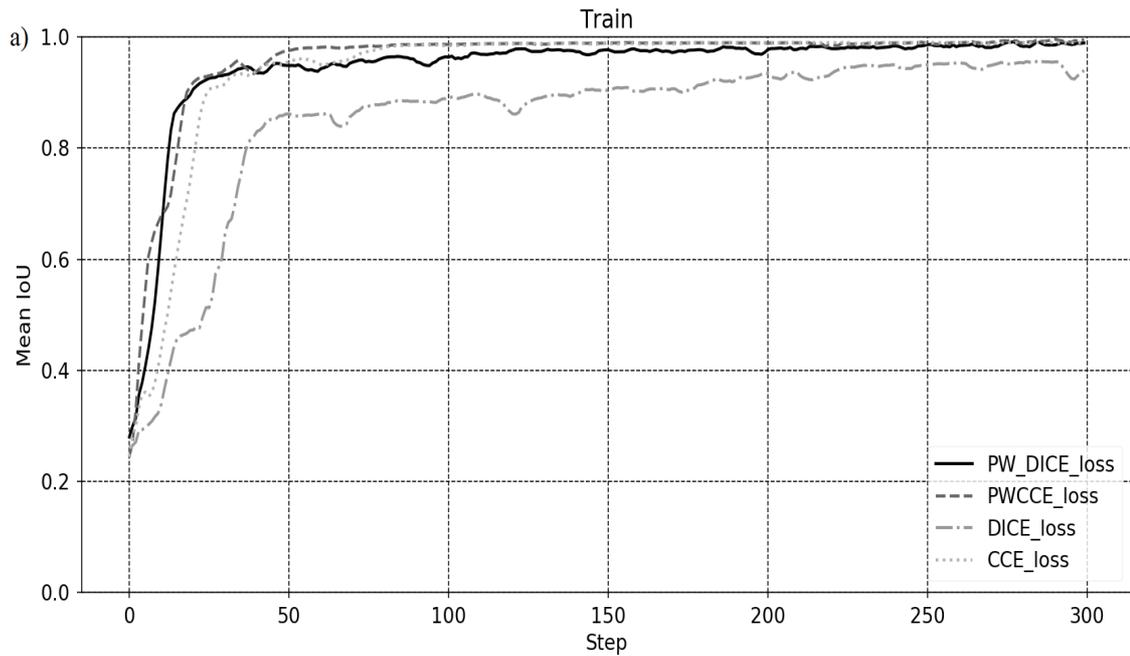


Рисунок 5.4 – Значение метрики Mean IoU во время обучения сети с разными функциями потерь на тренировочной выборке

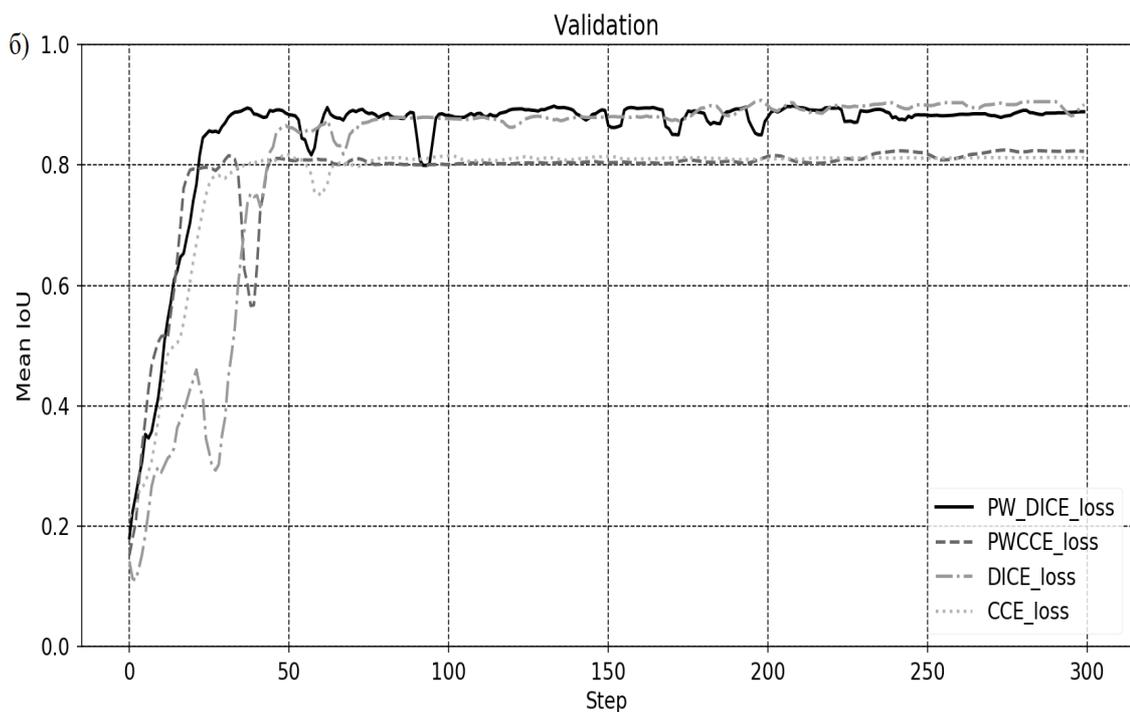


Рисунок 5.5 – Значение метрики Mean IoU во время обучения сети с разными функциями потерь на валидационной выборке

Некоторые из полученных предсказанных сегментов показаны на рисунке 5.6.

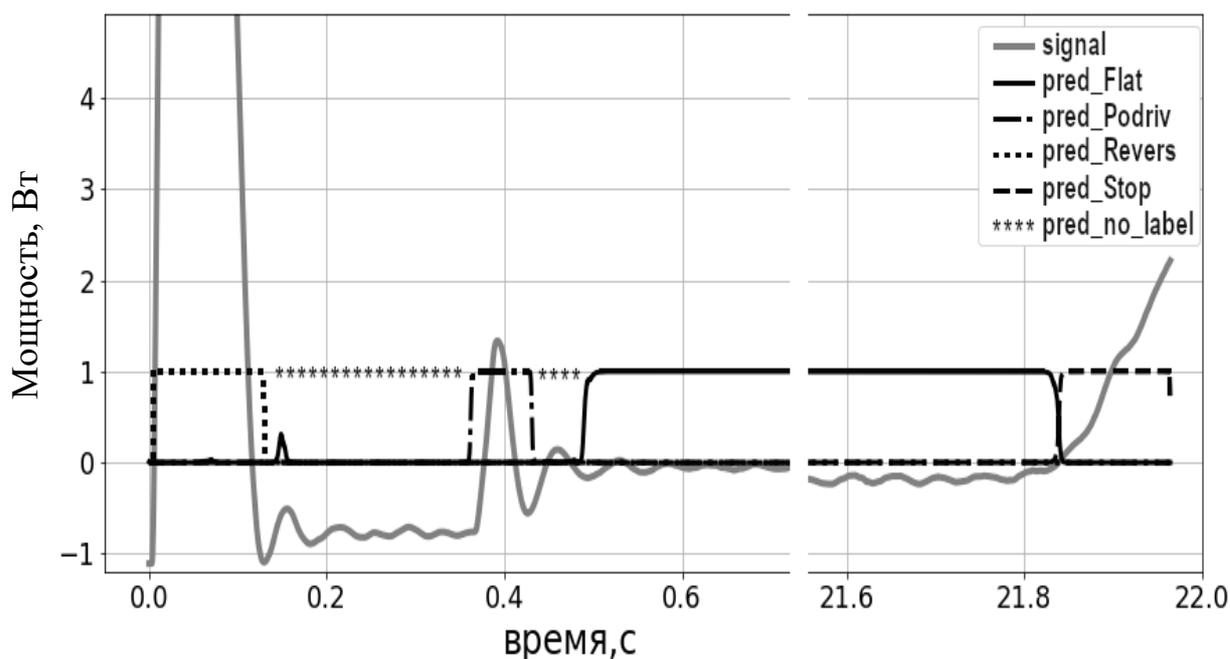


Рисунок 5.6 – Результат сегментации

Для более детальной оценки результатов сегментации в таблице 5.2 представлены значения метрики IoU для каждого отобранного участка, посчитанные сетью с различными функциями потерь. Категориальная кросс-энтропия приводит к лучшим результатам на обучающей выборке, но к худшим при валидации, что указывает на лучшую обобщающую способность функции Dice. Как видно из графиков, добавление в функцию потерь пиксельного взвешивания приводит к лучшей сходимости сети, и в случае Dice-loss (PW_DICE_loss) значение метрики Mean IoU на 5-10% больше на тренировочной выборке, чем у Dice (DICE_loss) без взвешивания. Однако на тестовой выборке у этих функций потерь значение метрики Mean IoU примерно одинаково.

Таблица 5.2 – IoU по классам (в процентах) на тестовой выборке

Название класса	Функция потерь			
	PW_Dice_loss	PWCCE_loss	Dice_loss	CCE_loss
Revers	98.12	97.98	97.68	98.28
Podriv	81.32	71.44	92.60	73.21
Flat	99.65	99.64	99.73	99.14
Stop	69.38	62.61	71.65	63.01
no_label	88.49	87.99	90.06	87.32

5.8 Выводы к главе 5

В данной главе был рассмотрен новый подход к сегментации сигналов активной мощности ЭПА с использованием сверточной нейронной сети. Была проведена оценка качества модели с использованием метрики «пересечение над объединением» (IoU) и функциями потерь Dice, PWCCE, CCE и PW_Dice. Было установлено, что функция потерь Dice позволяет достичь лучших результатов, в то время как категориальная кросс-энтропия приводит к лучшим результатам на обучающей выборке, но к худшим при валидации, что указывает на лучшую обобщающую способность функции Dice.

Нейронная сеть, разработанная в рамках данной главы, показала результаты высокого качества. Она позволяет автоматизировать процесс диагностирования ЭПА [128], значительно увеличить скорость диагностирования и выявления неисправностей ЭПА, исключить возможные ошибки, связанные с влиянием человеческого фактора.

За счет автоматизации процесса разбиения сигналов активной мощности на сегменты, диагностирование технического состояния ЭПА стало возможно проводить как в офлайн формате, так и в онлайн формате.

Таким образом, результаты данной работы могут быть применены в различных областях, связанных с диагностированием и контролем технического состояния электроприводной арматуры, а также могут служить основой для дальнейших исследований в данной области.

ОСНОВНЫЕ ВЫВОДЫ И ЗАКЛЮЧЕНИЕ

В атомной отрасли сосредоточен беспрецедентный интеллектуальный потенциал с уникальными знаниями как в предметной атомной области, так и в области обработки данных.

С внедрением предиктивной аналитики ожидается, что диагностирование РУ трансформируется в сторону:

- построения новых предикторов ресурса, прочности, надежности, вибросостояния за счет анализа данных большей размерности, на большую временную глубину, с прогнозом на длительную перспективу;

- увеличения наблюдаемости необслуживаемого в эксплуатационных условиях оборудования первого контура РУ;

- обоснованного прогноза ресурса незаменимого при продлении срока эксплуатации оборудования.

Методы предиктивной аналитики диагностирования РУ должны разрабатываться и внедряться, прежде всего, для стационарных систем диагностирования РУ.

Внедренными на РУ ВВЭР стационарными системами диагностирования, число которых перевалило за сотню, накоплены невероятные по диагностической ценности многолетние базы данных. Они должны стать экспериментальной основой развития методов предиктивной аналитики.

В диссертационной работе:

1. Разработан и внедрен на Новоронежской АЭС-2 (Энергоблок №1) алгоритм выделения полезного сигнала в измерительных каналах системы акустического контроля течей, который обеспечивает более точную диагностику течей и более высокую надежность определения протечек трубопроводов РУ, за счет сокращения числа ошибок первого рода (ложных срабатываний), а также более высокую чувствительность, что позволяет обнаруживать течи с расходом менее установленного концепцией «течь перед разрушением».

Исследована устойчивость предложенного алгоритма к различным фоновым акустическим выбросам. Он предполагает первоначальное построение регрессионных моделей и последующую обработку остаточных сигналов с помощью фильтра Калмана. Работоспособность алгоритма была подтверждена моделированием сценария течи с использованием модельных данных, полученных на основе экспериментального обоснования САКТ на специализированном стенде, а также на имеющихся данных по протечкам на номинальных параметрах, эксплуатируемых РУ.

2. Разработан новый метод проверки работоспособности ИК САКТ и определения неисправности ИК, основанный на использовании двух нейросетевых классификаторов. Этот метод позволяет выявлять дефекты в каналах с высокой точностью и, как следствие, повышает надежность и эффективность работы этих систем. Алгоритм был проверен на сигналах акустических датчиков САКТ НВАЭС-2 (Энергоблок №1), что подтвердило его способность не только детектировать наведенные помехи в измерительных каналах, но и определять неисправные акустические детекторы.

3. Разработан методический подход к обнаружению аномалий в работе реакторного оборудования, заключающийся в последовательном применении модели оценки состояния и модели обнаружения неисправностей. На основании данного подхода реализовано два алгоритма, в качестве модели оценки состояния в которых использовались вариационный автоэнкодер и многомерный метод оценки состояния (MSET), а также критерий Хотеллинга, использующий для анализа остаточные временные ряды (полученные путем вычитания каждого измеренного сигнала из его численно сгенерированного моделью оценки состояния аналога) в качестве модели обнаружения неисправностей.

Предложенный алгоритм позволяет определить покомпонентный вклад каждого отдельного временного ряда в суммарную статистику и локализовать неисправность на основе определения сигналов, внесших наибольший вклад в ее развитие, что помогает эксперту в определении истинной причины неисправности

оборудования и в составлении симптомно-ориентированной аварийной инструкции.

Алгоритм продемонстрировал высокую точность при тестировании на реальных данных, полученных с НВАЭС-2, на примере описания режимов работы четырех ГЦН. На основе этих данных были разработаны критерии диагностирования, которые позволяют выявлять аномалии в работе оборудования и принимать меры по их устранению.

4. Разработан алгоритм автоматической сегментации сигналов активной мощности ЭПА, представленных временными рядами, позволяющий автоматизировать процесс диагностирования ЭПА и повысить надежность диагностирования за счет исключения возможных ошибок, связанных с человеческим фактором. Проведен анализ наиболее подходящих функций потерь для решения проблемы сильной несбалансированности в размеченных классах.

Благодаря автоматизации процесса разбиения сигналов активной мощности на сегменты, диагностирование технического состояния ЭПА стало возможно проводить как в офлайн, так и в онлайн формате.

Алгоритм реализован в системе комплексного диагностирования арматуры АО «НТЦД». Ведутся работы по внедрению данной системы на Курскую АЭС.

Таким образом, важнейшая техническая задача реализации новых научно обоснованных технических решений, внедрение которых вносит значительный вклад в развитие страны, в сфере разработки, создания методов и алгоритмов диагностирования оборудования и повышения информативности штатных систем контроля оборудования и РУ в целом, имеющих важное значение для повышения безопасности и эксплуатационной надежности АЭС, решена.

СПИСОК ЛИТЕРАТУРЫ

1. A. Sanchez-Fernandez, F.J. Baldan, G.I. Sainz-Palmero, J.M. Benítez, M.J. Fuente. Fault detection based on time series modeling and multivariate statistical process control // *Chemometrics and Intelligent Laboratory Systems* – 2018 – vol.182 – pp.57-69.
2. Скоморохов А. О. Многомерные статистические методы диагностики аномальных состояний ЯЭУ / Дис. Д-ра. техн. наук: 05.14.03. – Обнинск, ИАТЭ НИЯУ МИФИ, 2011. – 302 с.
3. Аварии и инциденты на атомных электростанциях. -Уч.пособие ИАТЭ, г.Обнинск. -1992.
4. Антонов Б.В. Итоги эксплуатации АЭС России в 1995 г//Известия вузов. Ядерная энергетика. - 1996. -№3. -С.4-8.
5. Аркадов Г.В., Павелко В.И., Финкель Б.М. Системы диагностирования ВВЭР. – М.: Энергоатомиздат, 2010. – С. 391.
6. Advanced Surveillance, Diagnostic and Prognostic Techniques in Monitoring Structures, Systems and Components in Nuclear Power Plants. Nuclear Energy Series no. NP-T-3.14. – Vienna: INTERNATIONAL ATOMIC ENERGY AGENCY, 2013. Электронный ресурс: <https://www.iaea.org/publications/8763/advanced-surveillance-diagnostic-and-prognostic-techniques-in-monitoring-structures-systems-and-components-in-nuclear-power-plants> (дата доступа: 20.07.2019).
7. Hastie T., Tibshirani R., Friedman J. The Elements of Statistical Learning. – Springer New York, 2009. – 745 p.
8. Chiang L. H., Russell E. L., Braatz R. D. Fault Detection and Diagnosis in Industrial Systems. – Springer London, 2001. – 279 p.
9. Кацер Ю.Д., Козицин В.О., Максимов И.В. Методы обнаружения неисправностей оборудования АЭС // Известия Высших Учебных Заведений, Ядерная Энергетика. – 2019. – No 4.
10. Ma J., Jiang J. Applications of fault detection and diagnosis methods in

nuclear power plants: A review // *Progress in Nuclear Energy*. – 2011. – Vol. 53. – No. 3. – PP. 255-266.

11. Patel Himanshukumar R, Shah Vipul A. Fault Detection and Diagnosis Methods in Power Generation Plants-The Indian Power Generation Sector Perspective: An Introductory Review // *PDP Journal of Energy and Management*. – 2018. – Vol. 2. – No. 2. – PP. 31-49.

12. ГОСТ Р ИСО 13381-1 – 2016. Контроль состояния и диагностика машин. Прогнозирование технического состояния. Часть 1. Общее руководство. – М.: Стандартинформ, 2017. – 24 с.

13. Bishop C. M. *Pattern Recognition and Machine Learning*. – Springer-Verlag New York Inc., 2006. – P. 738.

14. Сергиенко А.Б. *Цифровая обработка сигналов*. – БХВ-Петербург, 2011. – С. 768.

15. Аркадов Г.В., Павелко В.И., Усанов А.И. *Виброшумовая диагностика ВВЭР*. – М.: Энергоатомиздат, 2004. – С. 344.

16. Katser ID, Kozitsin VO, Maksimov IV, Larionov DA, Kotsoev KI (2021) Data pre-processing methods for NPP equipment diagnostics algorithms: an overview. *Nuclear Energy and Technology* 7(2): 111-125.

17. Zavaljevski N., Gross K. C. Sensor fault detection in nuclear power plants using multivariate state estimation technique and support vector machines // *Third International Conference of the Yugoslav Nuclear Society YUNSC 2000*. – 2000.

18. Li W., Peng M., Wang Q. False alarm reducing in PCA method for sensor fault detection in a nuclear power plant // *Annals of Nuclear Energy*. – 2018. – aug. – Vol. 118. – P. 131–139.

19. Li W., Peng M., Liu Y. et al. Fault detection, identification and reconstruction of sensors in nuclear power plant with optimized PCA method // *Annals of Nuclear Energy*. – 2018. – mar. – Vol. 113. – P. 105–117.

20. Li W., Peng M., Wang Q. Improved PCA method for sensor fault detection and isolation in a nuclear power plant // *Nuclear Engineering and Technology*. – 2019.

– feb. – Vol. 51, no. 1. – P. 146–154.

21. Honghai F., Guoshun C., Cheng Y. et al. A SVM regression based approach to filling in missing values // International Conference on Knowledge-Based and Intelligent Information and Engineering Systems / Springer. – 2005. – P. 581–587.

22. Batista G. E., Monard M. C. A Study of K-Nearest Neighbour as an Imputation Method. // HIS. – 2002. – Vol. 87, no. 251-260. – P. 48.

23. Gupta A., Lam M. The weight decay backpropagation for generalizations with missing values // Annals of Operations Research. – 1998. – Vol. 78. – P. 165–187.

24. Li D., Deogun J., Spaulding W. et al. Towards missing data imputation: a study of fuzzy k-means clustering method // International Conference on Rough Sets and Current Trends in Computing / Springer. – 2004. – P. 573–579.

25. Wohlrab L., Fürnkranz J. A Comparison of Strategies for Handling Missing Values in Rule Learning. Technical Report TUD-KE-2009-03, 2009.

26. Загоруйко Н. Г. Прикладные методы анализа данных и знаний. – Изд-во Ин-та математики Новосибирск, 1999. – С. 260.

27. Aggarwal C. C. Outlier Analysis // Data Mining: The Textbook. – Cham: Springer International Publishing, 2015. – P. 237–263.

28. Aggarwal C. C., Sathe S. Outlier ensembles: An introduction. – Springer, 2017. – P. 275.

29. Zhao Y., Nasrullah Z., Hryniewicki M. K. et al. LSCP: Locally Selective Combination in Parallel Outlier Ensembles // Proceedings of the 2019 SIAM International Conference on Data Mining. – Society for Industrial and Applied Mathematics, 2019. – may. – P. 585–593.

30. Shalabi L. A., Shaaban Z., Kasasbeh B. Data Mining: A Preprocessing Engine // Journal of Computer Science. – 2006. – sep. – Vol. 2, no. 9. – P. 735–739.

31. Sakia R. M. The Box-Cox Transformation Technique: A Review // The Statistician. – 1992. – Vol. 41, no. 2. – P. 169.

32. Tibshirani R. Regression shrinkage and selection via the lasso // Journal of the Royal Statistical Society: Series B (Methodological). – 1996. – Vol. 58, no. 1. –

P. 267-288.

33. Аркадов Г.В., Павелко В.И., Слепов М.Т. Виброакустика в приложениях к реакторной установке ВВЭР - 1200. – М.: Наука, 2018. – 391 с.

34. Kano M., Tanaka S., Hasebe S. et al. Monitoring independent components for fault detection // *AIChE Journal*. – 2003. – apr. – Vol. 49, no. 4. – P. 969–976.

35. Zhang Y., Qin S. J. Fault Detection of Nonlinear Processes Using Multiway Kernel Independent Component Analysis // *Industrial & Engineering Chemistry Research*. – 2007. – nov. – Vol. 46, no. 23. – P. 7780–7787.

36. MacGregor J., Kourti T. Statistical process control of multivariate processes // *Control Engineering Practice*. – 1995. – mar. – Vol. 3, no. 3. – P. 403–414.

37. Haroon D. R., Szedmak S., Shawe-Taylor J. Canonical Correlation Analysis: An Overview with Application to Learning Methods // *Neural Computation*. – 2004. – dec. – Vol. 16, no. 12. – P. 2639–2664.

38. Kaya H., Eyben F., Salah A. A. et al. CCA based feature selection with application to continuous depression recognition from acoustic speech features // 2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). – IEEE, 2014. – may.

39. Harman H. H. Modern factor analysis. – University of Chicago press, 1976. – P. 522.

40. Ким Дж. О. Факторный, дискриминантный и кластерный анализ. – Рипол Классик, 1989. – С. 215.

41. Лескин С.Т., Слободчук В.И., Шелегов А.С. и др. Диагностика ГЦН ВВЭР-1000 по данным оперативно-технологического контроля. // Сборник трудов 7-й МНТК «Обеспечение безопасности АЭС с ВВЭР». – 2011.

42. Аркадов Г.В., Трыкова И.В., Коцоев К.И. Кластеризация акустических событий в главном циркуляционном контуре реакторной установки с ВВЭР-1000/1200, обусловленных штатными технологическими операциями. *Глобальная Ядерная Безопасность*. 2022;(3):43-55. <https://doi.org/10.26583/gns-2022-03-04>

43. Chandola V., Banerjee A., Kumar V. Anomaly detection // *ACM Computing*

Surveys. –2009. – Vol. 41. – No. 3. – PP. 1-58.

44. Tartakovsky A., Nikiforov I., Basseville M. Sequential analysis: Hypothesis testing and changepoint detection. – Chapman and Hall/CRC, 2014. – 575 p.

45. ГОСТ Р ИСО 7870-1-2011 Статистические методы. Контрольные карты. Часть 1. Общие принципы. ИСО 7870-1-2011. – М.: Стандартинформ, 2011. – 16 с.

46. Ивановский Р. И. Теория вероятностей и математическая статистика. Основы, прикладные аспекты с примерами и задачами в среде MathCad. – БХВ-Петербург, 2008. – 528 с.

47. Wald A. Sequential analysis. – Courier Corporation, 1973. – 213 p.

48. Xin Jin, Yin Guo, Soumik Sarkar et al. Anomaly Detection in Nuclear Power Plants via Symbolic Dynamic Filtering // IEEE Transactions on Nuclear Science. – 2011. – Vol. 58. – No. 1. – PP. 277-288.

49. Di Maio F., Baraldi P., Zio E. et al. Fault Detection in Nuclear Power Plants Components by a Combination of Statistical Methods // IEEE Transactions on Reliability. – 2013. – Vol. 62. – No. 4. – PP. 833-845.

50. A. Ferrer, Statistical control of measures and processes, Comprehensive Chemometrics - Chemical and Biochemical Data Analysis 1 (2009) 97–126.

51. W. Shewhart, Application of statistical methods to manufacturing problems, Journal of the Franklin Institute 226 (2) (1938) 163 – 186.

52. R. Woodward, P. Goldsmith, Cumulative sum techniques, Mathematical and Statistical Techniques for Industry, Oliver & Boyd Edinburgh, 1964., E. S. Page, Continuous inspection schemes, Biometrika 41 (1-2) (1954) 100–115.

53. J. Hunter, The exponentially weighted moving average, Journal of Quality Technology 18(4) (1986) 203–210.

54. H. Kaneko, K. Funatsu, A new process variable and dynamics selection method based on a genetic algorithm-based wavelength selection method, AIChE Journal 58(6) (2012) 1829–1840.

55. Ross T.J. Fuzzy Logic with Engineering Applications. John Wiley & Sons, Ltd, 2010. 585 p.

56. Shahinpoor M., Wells D. Applications possibilities for fuzzy failure analysis, and diagnosis of reactor plant components and areas. *Nuclear Engineering and Design*, 1980, 61 (1), pp. 93-100.

57. Choi S.S., Kang K.S., Kim H.G., Chang S.H. Development of an on-line fuzzy expert system for integrated alarm processing in nuclear power plants. *IEEE Transactions on Nuclear Science*, 1995, 42 (4), pp. 1406-1418.

58. Chang S.H., Kang K.S., Choi S.S., Kim H.G., Jeong H.K., Yi C.U. Development of the on-line operator aid system OASYS using a rule-based expert system and fuzzy logic for nuclear power plants. *Nuclear Technology*, 1995, 112 (2), pp. 266-294.

59. A.K.S. Jardine, D. Lin, D. Banjevic: A Review on Machinery Diagnostics and Prognostics Implementing Condition-based Maintenance, *Mechanical System and Signal Processing*, Vol. 20, No. 7, Oct. 2006, pp. 1483 – 1510.

60. G. Vachtsevanos, F. Lewis, M. Roemer, A. Hess, B. Wu: *Intelligent Fault Diagnosis and Prognosis for Engineering Systems*, John Wiley & Sons, NJ, USA, 2006.

61. Bolander, H. Qiu, N. Eklund, E. Hindle, T. Rosenfeld: Physics-based Remaining useful Life Prediction for Aircraft Engine Bearing Prognosis, *Conference of the Prognostics and Health Management Society*, San Diego, CA, USA, Sept. 2009.

62. S.J. Julier, J.K. Uhlmann: A New Extension of the Kalman Filter to Nonlinear Systems, *11th International Symposium on Aerospace/Defense Sensing, Simulation and Control*, Orlando, USA, April 1997, pp. 182 – 193.

63. M. Orchard, G. Vachtsevanos: A Particle Filtering-based Framework for Real-time Fault Diagnosis and Failure Prognosis in a Turbine Engine, *15th Mediterranean Conference on Control and Automation*, Athens, Greece, July 2007.

64. L. Ljung: *System Identification: Theory for the User*, Prentice-Hall, NJ, USA, 1999.

65. Chollet F. *Deep Learning with Python: Second Edition*. – Manning Publications. – 2017. – 384 p.

66. Brockwell P. J, Davis R. A, Calder M. V. *Introduction to time series and*

forecasting. – Springer, 2002. – Vol. 2. – 434 p.

67. Chatfield C. The Holt-Winters Forecasting Procedure // *Applied Statistics*. – 1978. – Vol. 27. – No. 3. – P. 264.

68. Gers F.A. Learning to forget: continual prediction with LSTM / *Proc. of the IX-th International Conference on Artificial Neural Networks: ICANN 99*. – IEE, 1999.

69. Pereira J. Unsupervised Anomaly Detection in Time Series Data using Deep Learning. / Thesis to obtain the Master of Science Degree in Electrical and Computer Engineering. – 2018. – Tecnico Lisboa. – 67 p.

70. Sakurada M., Yairi T. Anomaly Detection Using Autoencoders with Nonlinear Dimensionality Reduction // *Proceedings of the MLSDA 2014 2nd Workshop on Machine Learning for Sensory Data Analysis - MLSDA14*. – ACM Press, 2014.

71. Xiao H., Huang D., Pan Y. et al. Fault diagnosis and prognosis of wastewater processes with incomplete data by the auto-associative neural networks and ARMA model // *Chemometrics and Intelligent Laboratory Systems*. – 2017. – feb. Vol. 161. – P. 96–107.

72. Yang H.-H., Huang M.-L., Yang S.-W. Integrating Auto-Associative Neural Networks with Hotelling T2 Control Charts for Wind Turbine Fault Detection // *Energies*. – 2015. – oct. – Vol. 8, no. 10. – P. 12100–12115.

73. Grais E. M., Plumbley M. D. Single channel audio source separation using convolutional denoising autoencoders // *2017 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*. – IEEE, 2017. – nov.

74. Ghasedi Dizaji K., Herandi A., Deng C. et al. Deep Clustering via Joint Convolutional Autoencoder Embedding and Relative Entropy Minimization // *The IEEE International Conference on Computer Vision (ICCV)*. – 2017. – Oct.

75. Chen K., Hu J., He J. Detection and classification of transmission line faults based on unsupervised feature learning and convolutional sparse autoencoder // *IEEE Transactions on Smart Grid*. – 2018. – Vol. 9, no. 3. – P. 1748–1758.

76. Yao K., Cohn T., Vylomova K., Duh K., Dyer C. Depth-Gated LSTM. // *arXiv preprint*. – 2015, arXiv:1508.03790v4. – 6 p.

77. Hochreiter S., Schmidhuber J. Long short-term memory // *Neural computation*. – 1997. – Vol. 9, no. 8. – P. 1735–1780.

78. Graves A., Schmidhuber J. Framewise Phoneme Classification with Bidirectional LSTM and Other Neural Network Architectures. // *Neural networks*. – 2005. – Vol. 18. – PP. 602-610; DOI: 10.1016/j.neunet.2005.06.042.

79. Bahdanau D., Cho K. Bengio Y Neural machine translation by jointly learning to align and translate. // *arXiv preprint*. – 2014, arXiv:1508.04025v7. – 15 p.

80. Pereira J., Silveira M. Unsupervised anomaly detection in energy time series data using variational recurrent autoencoders with attention. – 2018 XVII-th IEEE International Conference on Machine Learning and Applications (ICMLA). – 2018. – 8 p. DOI: 10.1109/ICMLA.2018.00207.

81. ГОСТ Р 58328 2018. «Трубопроводы атомных станций. Концепция «течь перед разрушением»». – Электронный ресурс: <https://files.stroyinf.ru/Data/705/70505.pdf> (дата доступа 05.05.2020).

82. Трыков Е.Л., Кудряев А.А., Коцоев К.И., Ананьев А.А. Эффективный метод фильтрации глобальных шумов измерительных каналов систем контроля течей АЭС с РУ ВВЭР. // *Известия вузов. Ядерная энергетика*. – 2020. – № 4. – С. 86-95. DOI: <https://doi.org/10.26583/npe.2020.4.08>.

83. Скоморохов А. О., Кудряев А.А., Морозов С.А. Нейросетевые модели фильтрации сигналов и диагностирования течи трубопроводов ВВЭР. // *Известия вузов. Ядерная энергетика*. – 2010. – № 4. – С. 72-80.

84. Николенко С., Кадурын А., Архангельская Е. Глубокое обучение. – СПб.: Питер. – 2018. – 480 с.

85. Kruschke J.K. Bayesian estimation supersedes the T test. // *Journal of Experimental Psychology: General*. – 2013. – Vol. 142. – No. 2. – PP. 573-603; DOI: 10.1037/a0029146.

86. Cameron D.-P. Bayesian Methods for Hackers: Probabilistic Programming and Bayesian Inference. – Addison-Wesley Data and Analytics Series. – 2016. – 226 p.

87. Barber D. Bayesian Reasoning and Machine Learning. – Cambridge

University Press. – 2017. – 666 p.

88. Najim M. Modeling Estimation and Optimal Filtering in Signal Processing. – Wiley. – 2008. – 408 p.

89. Durbin J. and Koopman S. J. Time Series Analysis by State Space Methods: Second Edition. – Oxford Statistical Science Series. – OUP Oxford. – 2012. – 253 p.

90. Haykin S. Adaptive Filter Theory: Fifth edition. – Pearson. – 2014. – 907 p.

91. Grewal M.S. and Andrews A.P. Kalman Filtering: Fourth edition. – Wiley. – 2015. – 617 p.

92. Коцоев К.И., Трыков Е.Л., Кудряев А.А., Перевезенцев В.В. Разработка алгоритма определения неисправности измерительных каналов системы акустического контроля течей // Вестник МГТУ им. Н.Э. Баумана – 2021. – №3. – С. 100-112

93. Швецов Д.М., Е.Л. Трыков Е.Л., Лескин С.Т., А.Ю. Пузаков А.Ю. Анализ акустических сигналов течи для повышения чувствительности контроля за счет создания эффективных диагностических признаков. Известия Высших Учебных Заведений, Ядерная Энергетика. – 2018. – No 1. с. 112–121.

94. Лескин С.Т. Разработка алгоритмов распознавания аномалий в состоянии оборудования АЭС по анализу данных оперативного технологического контроля. Известия вузов. Ядерная энергетика. – 1997. – No 4. с. 4–12.

95. Cai Baoping, Huang Lei, Xie Min. Bayesian Networks in Fault Diagnosis // IEEE Transactions on Industrial Informatics. – 2017. – Vol. 13. – No. 5. – PP. 2227-2240.

96. Буянкин В.М, Захаров В.Г. Прогнозирование неисправностей электропривода с использованием нечеткой нейронной сети // Вестник Московского автомобильно-дорожного института (государственного технического университета). – 2007. – № 4. – С. 21-23.

97. Классификация и кластер. Под ред. Дж. Вэн Райзина. – М.: Мир, 1980. с. 212–217

98. Nilsson N. J. Introduction to Machine Learning. 1998.

99. Гайер А.В., Шешкус А.В., Чернышова Ю.С. Машинное обучение. Аугментация обучающей выборки «на лету» для обучения нейронных сетей. 2018.
100. A. Simoglou, E. Martin, A. Morris, Statistical performance monitoring of dynamic multivariate processes using state space modeling, *Computers & Chemical Engineering*, 26(6) (2002) 909–920.
101. Аркадов Г.В., Коцоев К.И. Лазарев Н.А. Павелко В.И. Трыков Е.Л. Трыкова И.В. Предиктивная аналитика и диагностика АЭС // Москва: Издательство «Наука», 2022, С. 143.
102. Kingma D. P., Welling M. Auto-Encoding Variational Bayes. // arXiv. – 2013.
103. Goodfellow I., Bengio Y., Courville A. *Deep Learning*. – MIT Press. – 2016. – 787 p.
104. J.W. Hines, D. Garvey, R. Seibert, and A. Usynin. *Technical Review of On-Line Monitoring Techniques for Performance Assessment Volume 2: Theoretical Issues*
105. Jian Peng, Linjun Fan, Weidong Xiao and Jun Tang. *Anomaly Monitoring Method for Key Components of Satellite*
106. Chaoyi Li, Jianzhong Sun, Hongfu Zuo. *Fault Detection for Air Conditioning System of Civil Aircraft Based on Multivariate State Estimation Technique*
107. An J., Cho S. Variational Autoencoder based Anomaly Detection using Reconstruction Probability. // arXiv preprint. –2015, arXiv:1802.03903v1. – 12 p.
108. Zhang C., Chen Y. Time Series Anomaly Detection with Variational Autoencoders. // arXiv preprint. – 2019, arXiv:1907.01702v1. – 7 p.
109. H Hotelling. Selected techniques of statistical analysis for scientific and industrial research and production and management engineering, chapter multivariate quality control, illustrated by the air testing of sample bombsights, 111–184, 1947.
110. I. Jolliffe, *Principal Component Analysis*, Springer Verlag New York, 2002. 28; T. Kourti, J. MacGregor, *Multivariate SPC methods for process and product*

monitoring, *Journal of Quality Technology* 28 (1996) 409–428.; C. F. Alcala, S. J. Qin, Reconstruction-based contribution for process monitoring, *Automatica* 45 (2009) 1593–1600.

111. Mujica L.E., Rodellar J., Fernandez A. et al. Q-statistic and T2-statistic PCA-based measures for damage assessment in structures // *Structural Health Monitoring: An International Journal*. – 2010. – Vol. 10. – No. 5. – PP. 539-553.

112. Zhao C., Gao F. Online fault prognosis with relative deviation analysis and vector autoregressive modeling // *Chemical Engineering Science*. – 2015. – Vol. 138. – PP. 531-543.

113. Li Wei, Peng Minjun, Wang Qingzhong. False alarm reducing in PCA method for sensor fault detection in a nuclear power plant // *Annals of Nuclear Energy*. – 2018. – Vol. 118. – PP. 131-139.

114. I. E. Jackson, *A User's Guide to Principal Components*, Wiley New York, 1991.

115. Jackson J., Mudholkar S. Control Procedures for Residuals Associated With Principal Component Analysis. // *Technometrics*. – 1979. – Vol. 21. – No. 3. – PP. 341-349.

116. Runger G. Alt, F., Montgomery D. Contributors to a Multivariate Statistical Process Control Chart Signal. // *Communications in Statistics. Theory and Methods*. – 1996. Vol. 25. – Iss. 10. – PP. 2203-2213.

117. Трыков Е.Л., Трыкова И.В., Коцоев К.И. Обнаружение аномалий в работе реакторного оборудования с помощью нейросетевых алгоритмов. // *Известия вузов. Ядерная энергетика*. – 2020. – № 3. – С. 136-147. DOI: <https://doi.org/10.26583/npe.2020.3.14>.

118. Коцоев К.И., Трыков Е.Л., Трыкова И.В. Применение свёрточной нейронной сети для сегментации сигналов электроприводной арматуры. // *Известия вузов. Ядерная энергетика*. – 2021. – № 2. – С. 158-167. DOI: <https://doi.org/10.26583/npe.2021.2.14>.

119. Abonyi J., Szeifert F., Babuska R. Modified Gath-Geva Fuzzy Clustering

for Identification of Takagi-Sugeno Fuzzy Models. // IEEE Systems, Man and Cybernetics, Part B. – 2002. – PP. 612-621.

120. Матвеев А.В., Жидков С.В., Адаменков А.К., Галивец Е.Ю., Усанов Д.А. Комплексный подход к диагностированию электроприводной арматуры применительно к задачам управления ресурсом. // Арматуростроение – 2009. – № 2 (59). – С. 53-59.

121. МТ 1.2.3.02.999.0085-2010. Методика «Диагностирование трубопроводной электроприводной арматуры». – М.: Росэнергоатом, 2010. – 239 с.

122. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. // arXiv:1505.04597v1 [cs.CV]. – 18 May 2015. – 8 p.

123. Long J., Shelhamer E., Darrell T. Fully Convolutional Networks for Semantic Segmentation. // arXiv:1411.4038v2 [cs.CV]. – 8 Mar 2015. – 10 p.

124. Xiaoya Li. Dice Loss for Data-imbalanced NLP Tasks. // arXiv:1911.02855v3 [cs.CL]. – 29 Aug 2020. – 12 p.

125. Sorensen Th. A Method of Establishing Groups of Equal Amplitude in Plant Sociology Based on Similarity of Species Content and its Application to Analyses of the Vegetation on Danish Cc of the Vegetation on Danish Commons. // Biologiske Skrifter. – 1948. – Bind 5. – PP. 1-34.

126. Drozdal M., Vorontsov E., Chartrand G., Kadoury S., Pal Ch. The Importance of Skip Connections in Biomedical Image Segmentation. // arXiv:1608.04117v2 [cs.CV]. – 22 Sep 2016. – 9 p.

127. Kingma D.P., Ba J. Adam: A Method for Stochastic Optimization. // arXiv:1412.6980v9 [cs.LG]. 30 Jan 2017. – 15 p.

128. Трыков Е.Л., Трыкова И.В., Коцоев К.И. Экспертная нейросетевая система диагностирования электроприводной арматуры. // Известия вузов. Ядерная энергетика. – 2021. – № 3. – С. 72-83. DOI: <https://doi.org/10.26583/npe.2021.3.06>.