

Федеральное государственное автономное образовательное
учреждение высшего образования
«Национальный исследовательский
томский политехнический университет»

На правах рукописи

Смольников Никита Викторович

**ОБЕСПЕЧЕНИЕ ОПТИМАЛЬНЫХ ЭКСПЛУАТАЦИОННЫХ
ХАРАКТЕРИСТИК АКТИВНОЙ ЗОНЫ ИССЛЕДОВАТЕЛЬСКОГО
РЕАКТОРА ИРТ-Т МЕТОДАМИ МАШИННОГО ОБУЧЕНИЯ**

Специальность:

1.3.2 – Приборы и методы экспериментальной физики

Диссертация на соискание ученой степени
кандидата физико-математических наук

Научный руководитель:

кандидат физико-математических наук

Наймушин Артем Георгиевич

Томск – 2025

Оглавление

Введение.....	4
Глава 1. Искусственный интеллект и ядерные технологии	13
1.1 Подходы к созданию систем на основе искусственного интеллекта	13
1.2 Мировой опыт применения технологий искусственного интеллекта в атомной отрасли.....	20
1.3 Выводы по главе 1	28
Глава 2. Математическая реконструкция нуклидного состава ядерного топлива	30
2.1 Исследовательский ядерный реактор ИРТ-Т	30
2.1.1 Расчетное сопровождения эксплуатации реактора ИРТ-Т с использованием программного средства MSU-PTR.....	34
2.2 Предпосылки к оптимизации эксплуатационных характеристик активной зоны реактора ИРТ-Т.....	37
2.2.1 Неравномерность распределения энерговыделения.....	37
2.2.2 Детализация расчетной модели и возможности оптимизации процесса РСЭ	41
2.3 Концепция реконструкции нуклидного состава топлива	48
2.4 Формирование пространственных распределений выгорания в топливных элементах.....	53
2.5 Верификация и валидация метода реконструкции состава топлива	64
2.6 Результаты и выводы по главе 2.....	72
Глава 3. Прогнозное определение эксплуатационных характеристик активной зоны реактора ИРТ-Т	74
3.1 Статистический анализ распределений энергонапряженности и запаса реактивности.....	74
3.1.1 Статистические распределения значений энерговыделения и запаса реактивности.....	77
3.1.2 Определение корреляционных связей	88
3.2 Обобщение зависимостей формирования эксплуатационных характеристик активной зоны.....	92

3.2.1	Формирование значений КНРЭ в ячейках.....	92
3.2.2	Формирование значений запаса реактивности реактора.....	97
3.3	Разработка прогнозных моделей	100
3.2.1	Методы машинного обучения.....	101
3.2.2	Ансамблирование прогнозных моделей	105
3.2.3	Многозадачное обучение.....	110
3.4	Верификация и валидация прогнозных моделей	122
3.4.1	Интерпретация результатов и верификация структуры моделей	122
3.4.2	Валидация на основе эталонных расчетов и экспериментальных данных ..	128
3.4	Результаты и выводы по главе 3	134
Глава 4. Алгоритмизированный поиск оптимальных топливных загрузок активной зоны реактора ИРТ-Т		136
4.1	Формализация процесса направленного случайного поиска	137
4.1.1	Условия оптимизационного поиска и выбор алгоритма.....	137
4.1.2	Разработка модификационных операторов и процедуры оптимизации	139
4.2	Определение параметров поиска топливных компоновок	143
4.2.1	Определение параметров функции приспособленности.....	145
4.2.2	Регуляризация решений на основе симметрии топливных ячеек	149
4.3	Формирование оптимальных топливных компоновок активной зоны реактора ИРТ-Т	152
4.3.1	Тестирование на основе прошлых топливных циклов реактора.....	152
4.3.1	Опытная эксплуатация ГА	154
4.4	Результаты и выводы по главе 4.....	158
Заключение		160
Список используемых сокращений и аббревиатур		163
Список литературы		164

Введение

Актуальность темы исследования. С 2020 г. в Российской Федерации реализуется комплексная программа «Развитие техники, технологий и научных исследований в области использования атомной энергии», которая направлена на формирование безопасной и эффективной энергетической системы, основанной на перспективных ядерных, термоядерных, плазменных и иных технологиях, а также на увеличение экспорта ядерных технологий России. Развитие новых перспективных направлений и проектов включает создание научно-исследовательской и экспериментальной базы, а также оптимизацию существующих технологических решений, что является масштабной задачей.

Важную роль в развитии новых разработок играют исследовательские ядерные реакторы (ИЯР), обладающие компактными размерами активной зоны, большим количеством экспериментальных каналов и устройств. Работы, проводимые на базе ИЯР посвящены изучению фундаментальных и прикладных процессов, разработке новых технологий и материалов, а также наработке радиоизотопной продукции технического и медицинского назначения. Повышение производственных возможностей ИЯР – одно из ключевых направлений для увеличения объемов и качества проводимых исследований, которое требует проведения комплекса расчетно-экспериментальных работ для обоснования безопасности и эффективной эксплуатации.

Большой объем исследований, проводимых на базе ИЯР, осуществляется с использованием программных средств (ПС), которые позволяют моделировать физические процессы, протекающие в активной зоне. В качестве традиционного подхода к определению характеристик излучения используются математические модели на основе генератора случайных чисел (метод Монте-Карло, ММК) [1]. Они являются универсальными и обладают высокой точностью, что позволяет определять нейтронно-физические характеристики (НФХ) в гетерогенной структуре активной зоны. Моделирование вероятностных характеристик ММК требует больших (кластерных) вычислительных мощностей, что является существенным недостатком и накладывает ограничения на количество

проводимых расчетно-экспериментальных обоснований. Для нивелирования недостатков ММК распространено применение аналитических и инженерных кодов, позволяющих проводить оценочные (первичные) расчеты отдельных элементов и узлов, которые впоследствии могут быть уточнены. Однако ограничения и упрощения, реализованные в таких кодах, являются причиной накопления статистической ошибки, что может привести к неверному конечному результату.

Стремительное развитие информационных технологий, сопровождающееся ростом производительности вычислительных систем, открывает возможности для создания и адаптации новых методов моделирования. К таким подходам можно отнести инструменты и алгоритмы искусственного интеллекта (ИИ), которые используют не фундаментальные физические законы, а обобщенные статистические методы в совокупности с многолетним накопленным опытом (массивы данных). Ключевая особенность ИИ-моделей – возможность обучаться и обобщать характер распределений данных, что позволяет описывать изученные процессы, предсказывать новые значения и находить более оптимальные решения в задачах, где расчетные методы менее эффективны или не могут быть применены.

Использование технологий ИИ для решения проблем реакторной физики представляет научный и практический интерес, поскольку они могут быть адаптированы для широкого спектра задач, включая: мониторинг параметров, оптимизацию конструкции и режимов работы, обработку экспериментальных данных. Основная трудность, возникающая при разработке таких интеллектуальных систем, связана с инженерно-технической сложностью ядерных установок, что требует не только систематизации статистических методов и ИИ-алгоритмов, а также экспертного анализа при интерпретации обобщенных закономерностей, описывающих протекание физических процессов в ядерном реакторе.

В настоящей работе предложен подход, направленный на расширение существующих возможностей опережающего моделирования и оптимизацию эксплуатационных характеристик исследовательского ядерного реактора ИРТ-Т,

основанный на суррогатном (эмпирическом) моделировании [2] процессов формирования энерговыделения, запаса реактивности активной зоны и алгоритмизированном поиске схем загрузок топлива.

Объектом исследования в диссертационной работе является активная зона исследовательского ядерного реактора ИРТ-Т и ее компоненты: топливные элементы, поглощающие стержни и отражатель.

Предметами исследования в диссертационной работе являются пространственные характеристики выгорания, нуклидный состав топлива, процессы формирования, изменения энергонапряженности в топливных элементах и запаса реактивности активной зоны реактора ИРТ-Т в зависимости от топливных конфигураций и положений поглощающих стержней.

Целью диссертационной работы является расширение подходов опережающего моделирования и обеспечение оптимальных эксплуатационных характеристик активной зоны исследовательского реактора ИРТ-Т методами машинного обучения.

Для достижения поставленной цели были сформулированы следующие **задачи**:

– разработка метода математической реконструкции нуклидного состава топлива, учитывающего неравномерность выгорания в гетерогенной структуре ячеек и топливных элементов для восстановления актуальных состояний активной зоны реактора ИРТ-Т;

– разработка алгоритма генерации искусственных схем загрузок топлива для формирования массива данных, описывающего реактивностные характеристики активной зоны и особенности распределения энерговыделения в топливных элементах;

– разработка прогнозных ИИ-моделей для определения запаса реактивности, распределения энерговыделения в ячейках и наиболее напряженных топливных элементах активной зоны в зависимости от схемы загрузки топлива и положений поглощающих стержней;

– разработка метода алгоритмизированного поиска топливных конфигураций, основанного на механизмах метаэвристического генетического алгоритма и прогнозных моделях для формирования оптимальных НФХ активной зоны реактора ИРТ-Т.

Научная новизна. В диссертационном исследовании предложен и реализован подход, основанный на применении ПС MCU-PTR, прогнозных моделей и алгоритма адаптивного поиска топливных загрузок по заданным критериям. Это позволило объединить точность ММК со скоростью и гибкостью ИИ, расширить подходы опережающего расчетного сопровождения и формировать оптимальные эксплуатационные характеристики активной зоны реактора ИРТ-Т при перегрузках.

Впервые разработан алгоритм математической реконструкции нуклидного состава топлива, учитывающий неравномерность выгорания урана-235 в гетерогенной структуре тепловыделяющих сборок, что позволяет «воссоздавать» актуальные состояния активной зоны реактора ИРТ-Т с общей точностью не менее 97 %.

Впервые разработаны прогнозные ИИ-модели, позволяющие прогнозировать неравномерность распределения энерговыделения в ячейках, наиболее энергонапряженные топливные элементы и реактивностные характеристики активной зоны реактора ИРТ-Т в зависимости от эксплуатационных картограмм выгорания топлива и положений поглощающих стержней.

Впервые предложен и разработан метод случайного направленного поиска топливных загрузок, включающий в себя алгоритмы перестановок тепловыделяющих сборок на основе эволюционных механизмов и ИИ-модели для предсказания НФХ активной зоны. По сравнению с традиционным подходом, автоматизированный и адаптивный подбор схем загрузок активной зоны реактора ИРТ-Т основан на анализе и отборе подходящих решений среди 10-12 тысяч генерируемых вариантов, что обеспечивает формирование оптимальных НФХ.

Теоретическая и практическая значимость работы. Результаты, представленные в диссертационной работе, вносят вклад в развитие исследований, направленных на расширение существующих знаний и подходов к оптимизации эксплуатационных характеристик активных зон исследовательских реакторов и расчетному (опережающему) моделированию за счет предложенной архитектуры «прецизионный код – ИИ», которая позволяет определять НФХ и формировать оптимальные топливные конфигурации активной зоны реактора ИРТ-Т.

Подходы, предложенные для реконструкции нуклидного состава топлива и генерации случайных загрузок, позволили установить особенности процессов выгорания топлива и перераспределения энерговыделения в гетерогенной структуре топливных элементов активной зоны реактора ИРТ-Т. Это позволяет анализировать схемы загрузок топлива и оценивать предельные тепловые нагрузки на топливные элементы.

Разработанные на основе ИИ прогнозные модели учитывают степень выгорания топлива в ячейках, эффекты «отравления» бериллия и положения поглощающих стержней, что позволяет без применения ресурсозатратного ММК определять энергонапряженность топливных ячеек и реактивностные характеристики активной зоны реактора ИРТ-Т в условиях реальных эксплуатационных циклов.

Алгоритм адаптивного поиска на основе механизмов генетического алгоритма и ИИ-моделей обеспечивает подбор топливных конфигураций с оптимальными энергонапряженностью и запасом реактивности, что позволило увеличить скорость подготовки программ перестановок активной зоны в среднем в 240 раз, увеличить длительность кампаний реактора ИРТ-Т более чем на 11 % и повысить стабильность нейтронного излучения в экспериментальных каналах на 15 %.

Представленные результаты обладают потенциалом для дальнейшего развития, аттестации и внедрения в полномасштабный производственный цикл расчетного сопровождения на базе действующих исследовательских ядерных установок.

Методология диссертационного исследования состоит в использовании комплекса расчетных и статистических методов:

– для определения особенностей распределения выгорания в гетерогенной структуре топливных элементов и математической реконструкции полученных зависимостей применялись прецизионное ПС MCU-PTR, программная обработка результатов моделирования, их аппроксимация на основе закономерностей, характеризующих физические процессы в активной зоне реактора, а также одномерное сплайн-сглаживание по методу наименьших квадратов.

– для установления обобщенных закономерностей формирования энерговыделения в топливных ячейках были использованы инструменты статистики, в том числе, описательная статистика, корреляционный анализ и аппроксимация на основе полуэмпирических закономерностей. Разработка прогнозных моделей проводилась на основе алгоритмов машинного обучения и нейросетевых архитектур, для оценки которых применялись общепринятые и оригинальные статистические показатели (функции потерь).

– для оптимизации топливных загрузок был разработан оригинальный программный код, в котором отражены: интеграция модификаторов перестановок топлива с прогнозными моделями, математическая формализация функции приспособленности на основе взвешенной линейной комбинации целевых функций. Были разработаны оригинальные математические функции регуляризации процесса направленного поиска для формирования симметричных пар тепловыделяющих сборок, характеризующих реальные схемы загрузки активной зоны реактора ИРТ-Т.

Обработка расчетно-экспериментальных значений и сопоставление результатов проводились с использованием методов математической статистики.

Научные положения, выносимые на защиту:

1. Метод математической реконструкции нуклидного состава, учитывающий неравномерность выгорания в гетерогенной структуре топливных элементов, позволяет восстанавливать эксплуатационные состояния активной зоны реактора ИРТ-Т с погрешностью ядерных концентраций 3 %, пространственных

распределений не более 5 %, реактивных характеристик не более $0,38 \beta_{эфф}$, что не превышает максимальную погрешность аттестованной модели ПС MCU-PTR.

2. На основе интеграции прецизионного моделирования (ПС MCU-PTR) и машинного обучения разработаны объяснимые суррогатные ИИ-модели, которые учитывают картограммы выгорания топлива и положения поглощающих стержней, что позволяет предсказывать энергонапряженность топливных ячеек и реактивные характеристики эксплуатационных компоновок активной зоны реактора ИРТ-Т с погрешностями $0,036$ и $0,51 \beta_{эфф}$, соответственно.

3. Метод случайного направленного поиска на основе генетического алгоритма и прогнозных моделей обеспечивает подбор оптимальных схем загрузок активной зоны реактора ИРТ-Т, что позволяет увеличить эффективность использования топлива более чем на 11 %, повысить стабильность нейтронного излучения в экспериментальных каналах более чем на 15 %.

Соответствие паспорту научной специальности. Диссертационное исследование направлено на разработку математических методов анализа, обработки данных, моделирование физических процессов, протекающих в активной зоне, с целью определения и оптимизации эксплуатационных характеристик реактора ИРТ-Т, что соответствует паспорту научной специальности 1.3.2 Приборы и методы экспериментальной физики в части: п.8 «Разработка и создание средств автоматизации физического эксперимента», п.9 «Разработка методов математической обработки экспериментальных результатов», п.10 «Моделирование физических явлений и процессов».

Достоверность полученных результатов обеспечивается физической обоснованностью решаемых задач, использованием статистических методов обработки и анализа результатов, согласованностью с экспериментальными данными реактора ИРТ-Т и эталонными результатами прецизионного моделирования в ПС MCU-PTR.

Личный вклад автора состоит в постановке научной проблемы, цели и задач исследования, разработке алгоритмов и расчетных кодов, проведении расчетных исследований и подготовке экспериментальных данных. Автор

принимал участие в подготовке научных статей и представлении результатов работы на всероссийских и международных конференциях и семинарах. Результаты, представленные в диссертационном исследовании, получены автором лично или при его непосредственном участии.

Апробация работы

Основные результаты диссертационной работы были представлены на всероссийских и международных семинарах и конференциях:

- Technical Meeting on Safety Considerations in the Use of Advanced Technologies at Research Reactors, МАГАТЭ, Австрия, 2024 г.
- 8-я Международная конференция по глубокому обучению в вычислительной физике (DLCP2024), Москва, 2024 г.
- 32-я Всероссийская научно-техническая конференция «Нейтронно-физические проблемы атомной энергетики» («Нейтроника-2024»), Обнинск, 2024 г.
- XXIX Международная научно-техническая конференция студентов, аспирантов и молодых ученых «Научная сессия ТУСУР - 2024», Томск, 2024 г.
- X Международная конференция «Атомная энергетика, ядерные и радиационные технологии XXI века», Минск, 2024 г.
- XXIII научная школа молодых ученых ИБРАЭ РАН, Москва, 2024 г.
- Международная молодежная научная конференции «Тинчуринские чтения- 2024 «Энергетика и цифровая трансформация», Казань, 2024 г.
- Всероссийская научно-практическая конференция, посвященная 75-летию со дня основания Сибирского химического комбината «Новая технологическая платформа атомной энергетики», Томск, 2024 г.
- Всероссийская научно-практическая конференция «Новая технологическая платформа атомной энергетики», Томск, 2024 г.
- I Всероссийская научно-практическая конференции «Интеллектуальная энергетика», Томск, 2023 г.
- III Международная научная конференция молодых ученых, аспирантов и студентов, Томск, 2023 г.

– «Science and Youth TVEL» международная открытая научно-техническую конференция молодежного движения топливной компании АО «ТВЭЛ», Томск, 2023 г.

Публикации

По основным результатам исследований опубликованы 10 работ, из них 3 опубликованы в изданиях, рекомендованных ВАК, 7 в журналах, индексируемых базами данных SCOPUS и Web of Science.

Структура и объем

Диссертация состоит из введения, четырех глав, заключения и списка литературы из 131 наименования. Работа изложена на 177 страницах, включая 78 рисунков и 31 таблицу.

Глава 1. Искусственный интеллект и ядерные технологии

1.1 Подходы к созданию систем на основе искусственного интеллекта

Впервые термин «искусственный интеллект» был введен в 1956 г. на конференции в Дартмуте и включал в себя направления разработки алгоритмов для решения логических задач и игр на основе заранее сформированных правил и методов, поэтому «традиционный» ИИ не подразумевает использование данных для имитации интеллектуальных процессов [3].

В настоящее время ИИ - это широкая область науки, которая охватывает широкий спектр методов и подходов, включающих правила эвристики, поиск, распознавание речи, принятие решений, планирование и многие другие.

Наибольшее распространение, среди подходов к созданию интеллектуальных систем, получил вычислительный интеллект (ВИ), способный адаптироваться на основе данных, имитировать природные процессы, извлекать закономерности и делать прогнозы. Вычислительный интеллект включает в себя следующие компоненты:

- машинное обучение (МО) – основная часть ВИ, включает алгоритмы, которые учатся на данных для создания предсказательных моделей;
- глубокое обучение (ГО) – подмножество МО, где используются многослойные искусственные нейронные сети (ИНС), которые имитируют работу мозга и могут обучаться сложным представлениям данных;
- биологические алгоритмы (БА) – это группа вычислительных методов, вдохновлённых биологическими процессами, такими как эволюция, поведение роя и колонии, и работа иммунной системы. Решения могут быть гибкими и приближенными, а не строго детерминированными;
- нечеткая логика (НЛ) использует «размытие» вместо жёсткой бинарной логики, чтобы моделировать неопределенность в реальных задачах.

МО, как общий подход, и его подмножество – ГО наиболее распространены среди методов ВИ, что сформировало общую классификации ИИ, которая представлена на рисунке 1.1.

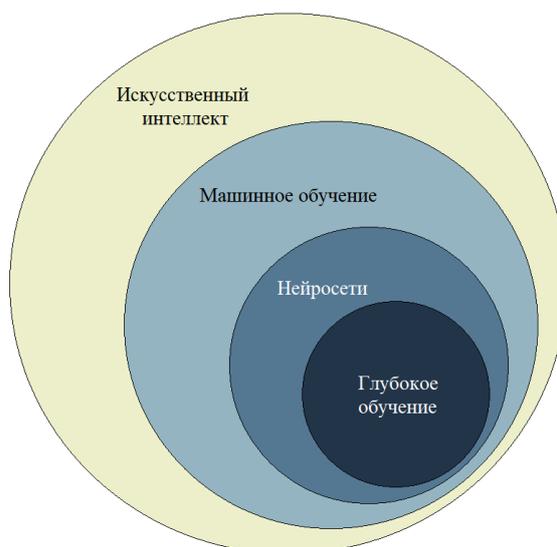


Рисунок 1.1 – Классификация определений в области ИИ

МО сосредоточено на разработке алгоритмов, которые позволяют системам автоматически извлекать «знания» из данных, при этом машины учатся решать задачи без прямого программирования. Вне зависимости от рассматриваемой задачи, МО осуществляет поиск и выявление закономерностей между данными для прогнозирования выходного признака. Для реализации классического подхода на основе МО необходимы:

- алгоритм, представляющий собой набор правил и математических моделей, на основе которых реализуется МО. Это могут быть модели линейной регрессии, деревья решений, методы опорных векторов, или ансамблевые методы;
- набор данных – матрица данных на которых осуществляется обучение алгоритма;
- признаки, описывающие индивидуальные свойства или характеристики наблюдаемого явления (объекта);

ГО, в свою очередь, ориентировано на использование многослойных искусственных нейронных сетей (ИНС) [4], которые позволяют работать с неструктурированными и высокоразмерными данными (рисунок 1.2). Извлечение признаков осуществляется автоматически на различных уровнях абстракции: нижние слои сети находят простые признаки (края на изображении), а более высокие слои строят сложные представления (лица или объекты).

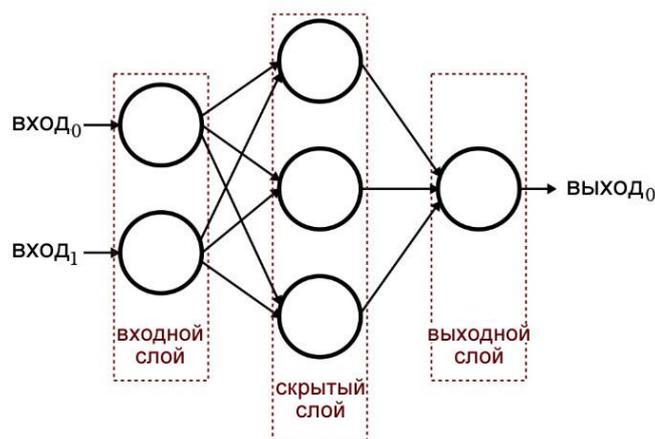


Рисунок 1.2 – Общая структура перцептона, представляющая собой ИНС

Основные отличия между МО и ГО представлены в виде сравнительной таблицы 1.1.

Таблица 1.1 – Сравнение особенностей МО и ГО

Критерий	МО	ГО
Архитектура моделей	Использует простые модели, такие как линейная регрессия, деревья решений, SVM, случайные леса	Использует многослойные нейронные сети (глубокие сети), такие как CNN, RNN, трансформеры
Инженерия признаков	Требует значительной ручной инженерии признаков для создания информативных признаков	Извлекает признаки автоматически на разных уровнях абстракции
Требования к данным	Может работать с меньшим количеством данных, особенно если признаки хорошо подготовлены	Требует больших объемов данных для обучения и получения качественных результатов
Тип данных	Эффективно работает с табличными, структурированными данными: численные и категориальные	Эффективно работает с неструктурированными данными, такими как изображения, аудио, текст.
Выбор гиперпараметров	Включает настройку небольшого числа гиперпараметров	Требует настройки большого количества гиперпараметров (количество слоев, размера фильтров, скорости обучения).
Вычислительные ресурсы	Может обучаться на стандартных процессорах (CPU) и требует	Требует мощных вычислительных ресурсов (GPU, TPU), особенно для глубоких сетей.

Критерий	МО	ГО
Интерпретируемость	относительно небольших вычислительных ресурсов. Как правило, более интерпретируемо. Модели, такие как линейная регрессия и деревья решений, легко объясняемы.	Модели часто являются «чёрными ящиками» ввиду глубокой структуры, что делает интерпретацию невозможной
Области применения	Финансовый анализ, медицина (диагностика), прогнозирование временных рядов, системы рекомендаций.	Компьютерное зрение, обработка естественного языка, голосовые помощники, генерация контента.
Гибкость и адаптивность	Менее гибкое по сравнению с ГО для сложных, нелинейных зависимостей; ограничено простыми зависимостями.	Очень гибкое для сложных, нелинейных зависимостей, позволяет моделировать сложные шаблоны и структуры.
Способность к генерации данных	Ограничено, обычно не используется для генерации новых данных.	Способно генерировать данные с использованием генеративных структур, что позволяет создавать новые, реалистичные образцы.

Ввиду наличия принципиальных отличий между подходами, при решении задач необходимо принимать во внимание сильные и слабые стороны методов.

Обобщенный математический вид задачи, решаемой в рамках МО, представляет собой проблему аппроксимации истинной функции согласно (1.1).

$$\hat{y} \approx y = \hat{f}(x, \theta) \approx f(x), \quad (1.1)$$

где,

x – элемент входных данных, так что $x \in \mathbf{X}$;

y – целевой признак, так что $y \in \mathbf{Y}$;

\mathbf{X}, \mathbf{Y} – массивы входных и целевых признаков, соответственно;

$\hat{f}(x, \theta)$ – аппроксимация функции $f(x)$;

θ – набор параметров для оптимизации.

Математическое выражение аппроксимирующей функции зависит от обучающего алгоритма. Так, аппроксимирующая функция традиционной линейной

регрессии МО – линейная комбинация параметров и входных данных, описанная согласно (1.2).

$$\hat{f}(x, \theta) = \theta_0 + \theta_1 x_1 + \theta_2 x_2 + \dots + \theta_d x_d, \quad (1.2)$$

где,

d – количество признаков (параметров).

Для ИНС, содержащей L слоев, аппроксимирующая функция имеет вид (1.3).

$$\hat{f}(x, \theta) = f_L^A(W_L f_{L-1}^A(\dots f_2^A(W_2 f_1^A(W_1 x + b_1) + b_2)\dots) + b_L), \quad (1.3)$$

где,

f_L^A – активационная функция;

W_L, b_L – веса и смещения для каждого слоя, соответственно. Совокупность весов и смещений представляет собой θ .

Подбор параметров, при которых достигается наилучшая сходимость исходных и прогнозных значений, является ключевой задачей обучения ИИ-системы и зависит от типа решаемой задачи (регрессия, классификация и др.), и парадигмы обучения. Для подбора параметров, как правило, используется метод стохастического градиентного спуска [5], при котором оценивается функция потерь (1.4).

$$\theta^* = \arg \min_{\theta} \sum_{i=1}^N L(y_i, \hat{f}(x_i, \theta)), \quad (1.4)$$

где,

N – размер обучающей выборки;

$L(y, \hat{f}(x, \theta))$ – функция потерь между истинными и прогнозными значениями;

θ^* – оптимальные параметры, при которых функция потерь минимальна.

В процессе подбора параметров принимается, что при минимальном значении функции потерь аппроксимирующая функция наиболее точно описывает распределение искомой функции (данных).

Таким образом, ИИ представляет собой широкую область, направленную на создание интеллектуальных систем. МО — это методология в рамках ИИ,

основанная на обучении моделей на данных, а ГО — это подход в МО, использующий многослойные ИНС.

Парадигмы обучения играют важную роль в процессе создания ИИ-системы и влияют на ее общую архитектуру. В настоящее время применение нашли следующие подходы к обучению:

- обучение с учителем (Supervised Learning – SL), при котором модель обучается на размеченных данных, где каждому входу соответствует конкретный выход;
- обучение без учителя (Unsupervised Learning – USL), при котором модель обучается на неразмеченных данных, где нет меток или целевых значений;
- обучение с подкреплением (Reinforcement Learning – RL), при котором модель (или агент) обучается взаимодействовать с окружающей средой и получать обратную связь в виде вознаграждений или наказаний;
- полуконтролируемое обучение (Semi-Supervised Learning – SemiSL) представляет собой сочетание элементов обучения с учителем и без учителя;
- самообучение (Self-Supervised Learning – SelfSL) представляет собой разновидность обучения без учителя, при котором модель учится предсказывать скрытую информацию из самих данных.

Как правило, выбор парадигмы обучения зависит от типа решаемой задачи, количества и качества данных, а также области применения модели, что оказывает существенное влияние на используемые алгоритмы, точность прогнозов и общую архитектуру интеллектуальной системы. Распространенность основных парадигм обучения описана диаграммой [6], представленной на рисунке 1.3.

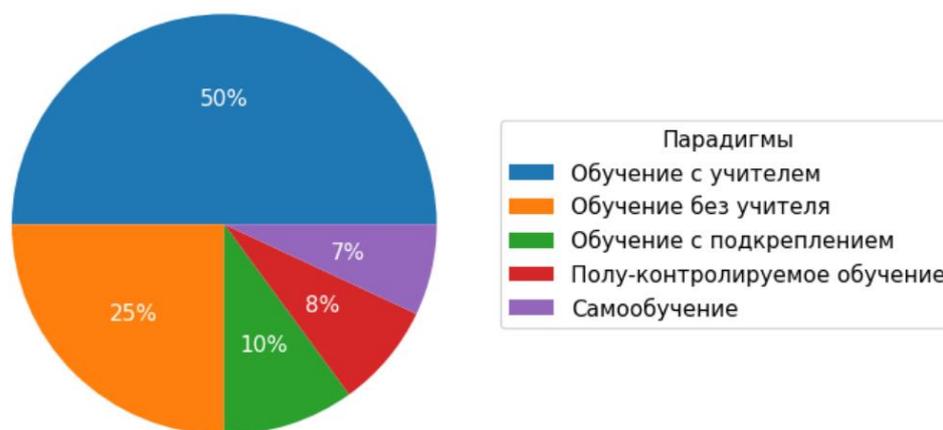


Рисунок 1.3 – Распространённость использования основных парадигм МО

Как можно видеть, полу-контролируемое обучение и самообучение имеют наименьшую распространённость, что обусловлено их новизной и архитектурной сложностью.

В отличие от МО, БА и НЛ представляют собой отдельные подходы к организации интеллектуальной системы и имеют ряд ключевых отличий:

1. БА применяется для поиска оптимальных решений в задачах с высокой сложностью и неопределённостью, или в NP-трудных задачах (недетерминированные с полиномиальным временем для которых не существует эффективных алгоритмов решения).

2. НЛ основана на «размытых» множествах и плавных переходах, и используется для обработки неопределённости и моделировании гибких решений [7].

Вне зависимости от выбранного подхода к разработке интеллектуальной системы или алгоритма обучения, общая схема (рисунок 1.4) включает в себя: постановку проблемы, инженериию данных, построение модели и развёртывание модели.

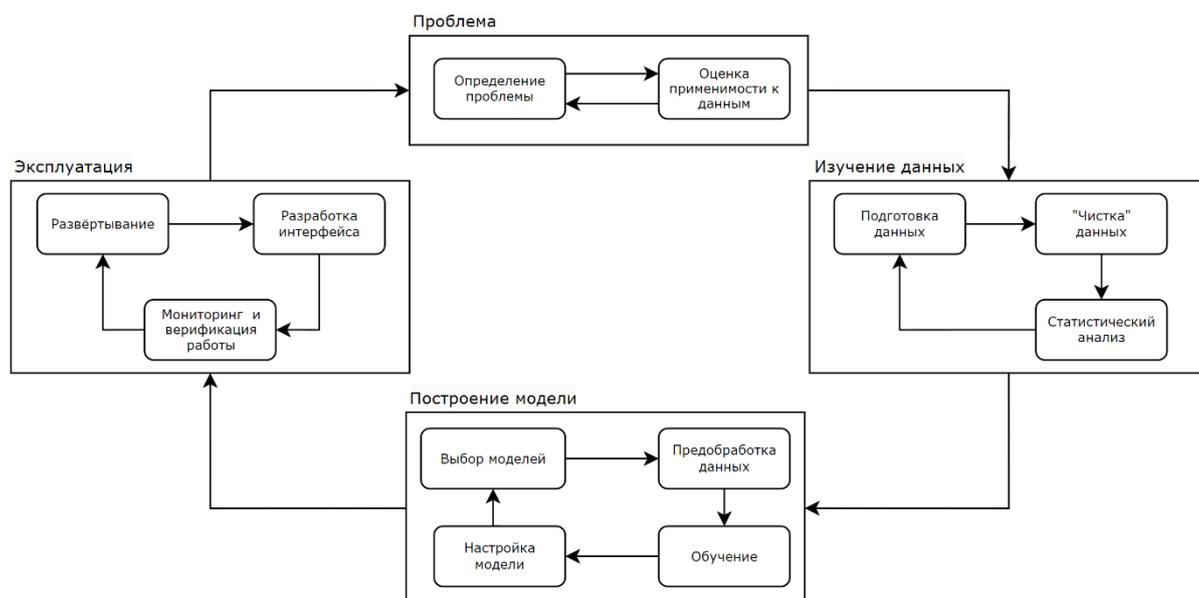


Рисунок 1.4 – Общая схема разработки и использования модели на основе искусственного интеллекта

Каждый из этапов состоит из промежуточных шагов, определяющих как качество используемых данных, так и эффективность выбранных алгоритмов. При решении задач на основе ИИ-систем общие и промежуточные этапы схемы могут претерпевать существенные изменения, что обусловлено особенностями архитектуры систем и их высокой адаптивностью.

1.2 Мировой опыт применения технологий искусственного интеллекта в атомной отрасли

Системы на основе ИИ нашли широкое применение в атомной отрасли, что обусловлено гибкостью алгоритмов ВИ, а также большими наборами данных, накопленными в результате многолетнего опыта [8]. Среди направлений развития ИИ в атомной отрасли наибольшее практическое применение получили системы, способные находить скрытые закономерности, что позволяет создавать модели для предсказания, анализа и оптимизации параметров отдельных элементов или создания рекомендаций и управления сложными системами, среди которых:

- мониторинг, анализ и автономный контроль параметров ядерной установки (ЯУ);
- анализ состояния реактора при работе в критических условиях;

- анализ возникновения аварийных ситуаций;
- оптимизация рабочих параметров реактора и конструкции активной зоны.

Исследования, посвященные мониторингу параметров ядерного реактора, считаются одними из первых, в которых были применены методы и алгоритмы ИИ. Так, в [9] описан переход от классического определения эффективности теплосъема на основе энергетического уравнения баланса к экспертной системе с ИНС.

Одна из первых концепций системы мониторинга работы ЯУ в режиме реального времени с возможностью оценки отклонений эксплуатационных параметров на основе автоассоциативной ИНС (рисунок 1.5) были предложена в рамках исследования [10].

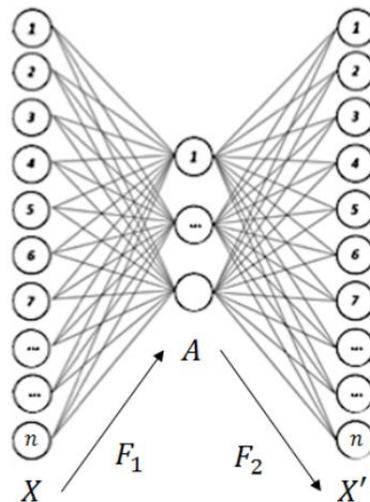


Рисунок 1.5 – Архитектура автоассоциативной ИНС: X – вход, A – пространство с меньшей размерностью; F – параметры

Авторы использовали автоассоциативную структуру для реализации подхода «обучение без учителя», что не требовало предварительной разметки и позволило использовать данные за длительный период эксплуатации. Однако, процесс тестирования показал, что переходные процессы и разные режимы эксплуатации не позволяют в полной мере использовать концепцию.

С повышением вычислительных мощностей количество исследований и разносторонность подходов к анализу параметров ЯУ, с использованием

МО [11–17] и ГО [18–26] стало стремительно расти. Некоторые подходы и их краткое описание представлены в таблице 1.2.

Таблица 1.2 – Применение технологий ИИ для мониторинга параметров

Подход	Применение	Результат
Метод опорных векторов	Концепт автономной системы мониторинга и анализ параметров транспортной ядерной установки TFHR на основе расчетных данных и МО [11].	Авторы рассматривают стационарные и переходные процессы в активной зоне в рамках модельных задач .
Многослойная ИНС	Анализ работы узлов системы охлаждения модульного ядерного реактора MASLWR [12].	Прогноз 16-ти параметров системы охлаждения и определение отклонений от установленных пределов.
Комплекс методов МО	Мониторинг технологических параметров активной зоны реактора типа PWR [14]	Рассмотрена динамика параметров в рамках топливной кампании для сектора активной зоны. В качестве исходных данных использовались результаты моделирования штатных режимов работы. Общая сходимость прогнозных значений составляет 0,95
Метод опорных векторов	Мониторинг динамики работы системы охлаждения реактора PWR [16]	В исследовательской работе рассмотрена возможность прогноза экспериментальных значений за годичный период эксплуатации установки. Модель обучалась предсказывать внештатное изменение режима работы. Погрешность прогнозов на тестовой выборке составила 4–6 %.
Многослойная ИНС	Анализ и прогноз концентрации борной кислоты и запаса реактивности при работе реактора PWR в стационарном режиме [18]	Рассмотрены расчетные параметры некоторых загрузок активной зоны. Статистическая ошибка прогнозирования не превышает 0,5 %. Отсутствие достоверных расчетных значений и динамики переходных процессов ограничивает функциональность подхода

Как можно видеть из описания, представленного в таблице 1.2, в качестве объектов мониторинга рассматриваются энергетические ЯУ, имеющие множество независимых систем детектирования эксплуатационных параметров, что обуславливает преимущественное использование ИНС для анализа входных

признаков. Авторы [13–15] отмечают, что анализ работы отдельных систем и элементов позволяет достичь наивысшей точности алгоритмов благодаря небольшому размеру исходной выборки.

Формирование условий для недопущения отказа оборудования, возникновения аварийной ситуации или её предотвращения – одни из наиболее важных задач при эксплуатации ЯУ. Традиционные подходы основаны на предварительных эмпирических расчетах [27–29] или моделировании в специализированных ПС: ATHLET, RELAP и др. [30–35], которые позволяют аналитически определять условия протекания сценариев и теплофизические параметры в установившемся режиме. Несмотря на общую сходимость с экспериментальными данными, авторы отмечают, что для учета многих факторов необходима детализация расчетных кодов.

Методы ИИ могут быть использованы для идентификации условий возникновения аварий [36–41], используя сигналы эксплуатационных систем реактора и оценки их протекания. Основной архитектурой ИИ-систем, использующихся для прогнозирования состояния объекта, является многослойная ИНС, что обусловлено большими объемами неструктурированных данных. На рисунке 1.6 представлен пример прогнозной модели на основе ИНС для оценки уровня теплоносителя в баке при аварийной ситуации [42].

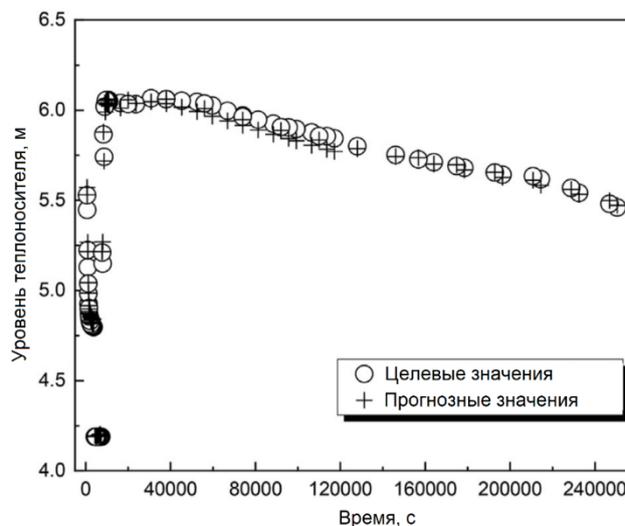


Рисунок 1.6 – Прогнозные возможности ИНС для оценки уровня теплоносителя в реакторе

Определение отклонений от рабочих параметров – не менее распространённая задача, в рамках которой оценивается динамика изменения параметров и их соответствие установленным пределам. Большое внимание уделяется формулировке проблемы и разработке алгоритмов, способных учитывать неопределенность и приближенные значения [43–52]. Авторы [43–45] отмечают, что в основу диагностических систем легли разработки моделей мониторинга параметров с внедрением дополнительных модулей детектирования отклонений. В таблице 1.3 представлены некоторые примеры подходов на основе ИНС с различной архитектурой и прогнозных моделей МО.

Таблица 1.3 – Применение технологий ИИ для оценки вероятности отказа оборудования и систем ЯУ.

Подход	Применение	Результат
Классификаторы МО	Классификация состояние модуля системы очистки теплоносителя для аварийного охлаждения реактора PWR [46]	Проведена оценка применимости ансамбля-классификаторов для оценки состояния экранов системы очистки теплоносителя для аварийного охлаждения. Авторы рассматривали эксплуатационные режимы, содержащие более 5200 циклов. Общая точность определения состояния составила 98 %.
Нечеткие нейронный сети	Непрерывный анализ технологических параметров активной зоны и систем реактора PWR [48]	Авторы предложили концепт интеллектуального контроллера на основе нечеткой нейронной сети. Контроллер осуществляет непрерывное сравнение регистрируемых параметров и генерирует выходной сигнал, характеризующий текущее состояние системы. В работе использовались искусственные данные, полученные на основе математической модели реактора и его систем.
ИНС ограниченная модель Больцмана (RBM)	Определение аномалий в работе систем реактора PWR [49]	В качестве входных данных авторы рассматривали результаты симуляции различных режимов (сценариев). Показано, что ИНС RBM может быть применена для выявления динамических изменений в работе установки.

Подход	Применение	Результат
Метод главных компонент (РСА)	Определение аномалий в работе датчиков систем реактора PWR [50]	Общая точность определения состояния реактора составила 97 %. Рассматривалась модельная задача на искусственно заданных выборках для определения состояния работы датчиков фиксации параметров. Авторы отмечают, что за счет высокой чувствительности РСА к шуму возможно эффективное определение текущего состояния датчиков.

Из таблицы 1.3 следует, что рассмотренные подходы существенно отличаются друг от друга, как методами решения, так и областями применения. Это свидетельствует о широкой направленности проблемы и особенностях разработки моделей, анализа и обработки больших массивов данных.

Наибольший интерес представляют работы, посвященные применению ИИ для решения задач оптимизации физических процессов и рабочих режимов эксплуатации, а также конструкции элементов ЯУ. Направления исследований можно условно разделить на следующие области:

- анализ и оптимизация теплогидравлических параметров [53–56];
- НФХ активных зон ЯУ [57–60]
- материаловедение [61–66]

Предлагаемые решения значительно превосходят традиционные расчетные коды благодаря высокой точности и скорости. Сводные результаты некоторых исследований приведены в таблице 1.4.

Таблица 1.4 – Применение технологий ИИ для анализа и оптимизации физических процессов в ЯУ

Подход	Применение	Результат
ИНС	Определение теплофизических характеристик облученного ядерного топлива [54]	Разработана универсальная модель, учитывающая пористость, состав и дозу облучения. Оцененная ошибка прогнозов составила менее 7% при сравнении с литературными данными.

Подход	Применение	Результат
Комплекс методов МО	Оценка коэффициента теплопередачи в системе охлаждения ИЯУ[56]	Проведена оценка применения методов МО для предсказания коэффициента теплопередачи. Показано, что модели МО на 40 % быстрее традиционных расчетных методов.
ИНС	Распределение мощности в активной зоне ВВЭР-1000 [57]	Показана возможность прогнозов распределения энерговыделения в активной зоне реактора ВВЭР-1000 с общей точностью 98 %. Снижение длительности расчетов более чем в 5 раз по сравнению с детерминистическими методами.
Градиентный бустинг	Определение остаточного тепловыделения в отработавшем ядерном топливе[63]	Проводилась оценка остаточного энерговыделения в зависимости от временного диапазона. Достигнута общая точность 95% на всем временном интервале.

Из сводной информации таблицы 1.4 и приведенных литературных данных следует, что методы МО и ГО могут быть использованы задач прогнозирования и анализа НФХ и теплогидравлических параметров с высокой точностью. При этом алгоритмы ГО наиболее оптимальны для задач трансмутации топлива и анализа ядерных данных, что обусловлено большой размерностью массивов данных.

Не менее важную роль играют исследования, посвященные проблемам оптимизации конструкции активной зоны ЯУ [67–72] для повышения НФХ за счет подбора оптимальных геометрических параметров топливных элементов, и формирования схем загрузок топлива с целью увеличения длительности топливных кампаний или снижения энергонапряженности отдельных участков активной зоны [73–80]. Некоторые оптимизационные подходы и достигнутые результаты приведены в сводной таблице 1.5.

Таблица 1.5 – Применение алгоритмов адаптивного поиска для оптимизации параметров ЯУ

Подход	Применение	Результат
Рой частиц	Формирование оптимальной конфигурации топливной ячейки реактора BWR [67]	Представлен однокритериальный поиск оптимальной конфигурации топливного блока. Авторы предложили критерии для

Подход	Применение	Результат
Генетический алгоритм	Повышение глубины выгорания ядерного топлива в реакторе PWR [76]	случайного направленного поиска, среди которых: обогащение, эффективный коэффициент размножения, величина энерговыделения. Представлены оптимизированные конфигурации, их эффективность оценивалась на основе моделирования. Предложены однокритериальная и многокритериальная оптимизационные функции, учитывающие: эффективный коэффициент размножения, глубину выгорания по активной зоне и энергонапряженность тепловыделяющих сборок (ТВС). Алгоритм осуществляет поиск исходя из условий максимизации или минимизации критериев, что позволяет исключать неподходящие решения.
Рой частиц	Определение оптимальной загрузки активной зоны реактора PARR1 [77]	Адаптация оптимизационного алгоритма для формирования картограммы загрузки активной зоны исследовательского реактора проводилась на основе значений эффективного коэффициента размножения и предельного значения энерговыделения. Предложен подход к моделированию НФХ на основе кода WIMSD-5B для расчета топливных ячеек

Алгоритмы оптимизационного поиска относительно заданных критериев показали свою применимость в задачах подбора конструкции элементов активной зоны и формирования топливных загрузок. Превалирующее количество исследований посвящено энергетическим ЯУ (PWR, BWR) при использовании фиксированных топливных конфигураций и типовых регламентов работы. Определение НФХ для анализируемых компоновочных решений осуществляется на основе приближенных аналитических расчетных моделей или инженерных кодов, которые рассматривают отдельные участки активной зоны и не позволяют анализировать все особенности гетерогенной структуры активной зоны реактора.

1.3 Выводы по главе 1

По результатам обзора современных подходов к созданию интеллектуальных систем и мирового опыта применения технологий ИИ в атомной отрасли, можно сделать следующие выводы:

– ВИ, как подход к созданию ИИ-систем, получил наибольшее распространение за счет высокой гибкости и адаптации на основе данных, а также возможности имитировать природные процессы, извлекать закономерности и делать прогнозы. Методы МО и ГО – многофункциональные инструменты для решения задач классификации, регрессии и генерации данных, каждый из которых обладает сильными и слабыми сторонами;

– ИИ-системы нашли широкое применение в атомной отрасли благодаря универсальности методов ВИ, которые позволяют создавать модели для автономного мониторинга и контроля, что является важной частью анализа состояния ЯУ при работе в номинальных и критических условиях. Анализ подходов к прогнозированию эксплуатационных параметров показал, что методы МО и ГО позволяют оценивать особенности протекания физических процессов с общей точностью $> 95\%$. Алгоритмы адаптивного поиска могут быть использованы для оптимизации существующих конструктивных решений и формирования схем загрузок топлива, направленных на повышения эффективности эксплуатационных режимов ЯУ.

– Несмотря на то, что проблемы, решаемые научными коллективами, имеют сходства и характерны для большинства рассмотренных ЯУ, присутствуют существенные отличия в использовании методов и парадигм обучения, что отражается на сложности архитектурных решений, скорости и общей точности работы алгоритмов.

Большое количество исследований посвящено адаптации технологий ИИ для энергетических ЯУ, которые имеют существенные конструктивные и инженерно-технические отличия от ИЯУ, предназначенных для проведения фундаментальных и прикладных исследований на базе экспериментальных

устройств. Существующие ИИ-подходы к ИЯУ затрагивают единичные оптимизационные задачи в рамках исследовательских работ без привязки к экспериментальным циклам работы реактора.

Вопросы повышения безопасности и эффективности работы ИЯУ играют важную роль в развитии новых технологий и материалов, поэтому их решение является актуальной проблемой атомной отрасли страны. Разработка ИИ-технологий, их систематизация и адаптация, направленные на решение актуальных задач ИЯУ, должны учитывать конструкционные особенности, физические процессы и реальные эксплуатационные режимы. Это требует разработки унифицированного и комплексного подхода, что представляет особый научный и практический интерес.

Глава 2. Математическая реконструкция нуклидного состава ядерного топлива

2.1 Исследовательский ядерный реактор ИРТ-Т

Реактор ИРТ-Т – среднепоточный исследовательский ядерный реактор бассейнового типа тепловой мощностью 6 МВт, введен в эксплуатацию после масштабной модернизации в 1984 году [81]. В качестве теплоносителя, замедлителя и верхней биологической защиты используется деминерализованная вода. Реактор предназначен для проведения научно-исследовательских работ в области физики твердого тела, нейтронно-активационному анализу, нейтронно-трансмутационному легированию кремния и др. [82]. Основные характеристики реактора ИРТ-Т представлены в таблице 2.1.

Таблица 2.1 – Характеристики реактора ИРТ-Т

Параметр	Значение
Номинальная мощность, МВт	6
Количество ТВС в активной зоне, шт	20
Поверхность теплоотдачи активной зоны, м ²	29,6
Рабочие органы (РО) системы управления и защиты (СУЗ), шт	9
— аварийной защиты	2
— компенсирующие	6
— автоматического регулирования	1
Суммарная эффективность РО СУЗ, $\beta_{эфф}$	21,4
Плотность потока тепловых нейтронов (ППТН)	
— в центральной бериллиевой ловушке	$1,8 \cdot 10^{14}$
— в вертикальных экспериментальных каналах	$5,0 \cdot 10^{13}$

Активная зона реактора набрана из ТВС типа ИРТ-3М, обогащенных до 90 % по изотопу U-235 (таблица 2.2).

Таблица 2.2 – Характеристики ТВС типа ИРТ-3М

Параметр	Восьмитрубная ТВС	Шеститрубная ТВС
Доля объема ячейки, занятая водой	0,625	0,548
Поверхность теплообмена в единице объема активной зоны, см ² /см ³	5,25	4,62
Высота активной зоны, см	60	60

Параметр	Восьмитрубная ТВС	Шеститрубная ТВС
Содержание урана-235 в ТВС, г	300	265
Концентрация урана-235 в активной зоне, г/л	101	89
Количество урана-235, приходящегося на 1 м ² поверхности теплообмена, г/м ²	192	192
Поверхность теплоотдачи ТВС, м ²	1,56	1,37

ТВС состоит из трубчатых твэлов квадратного сечения с толщиной стенки 1,4 мм. Оболочка выполнена из алюминиевого сплава САВ-1 толщиной 0,5 мм. Сечение восьмитрубной и шеститрубной ТВС типа ИРТ-3М представлено на рисунке 2.1.

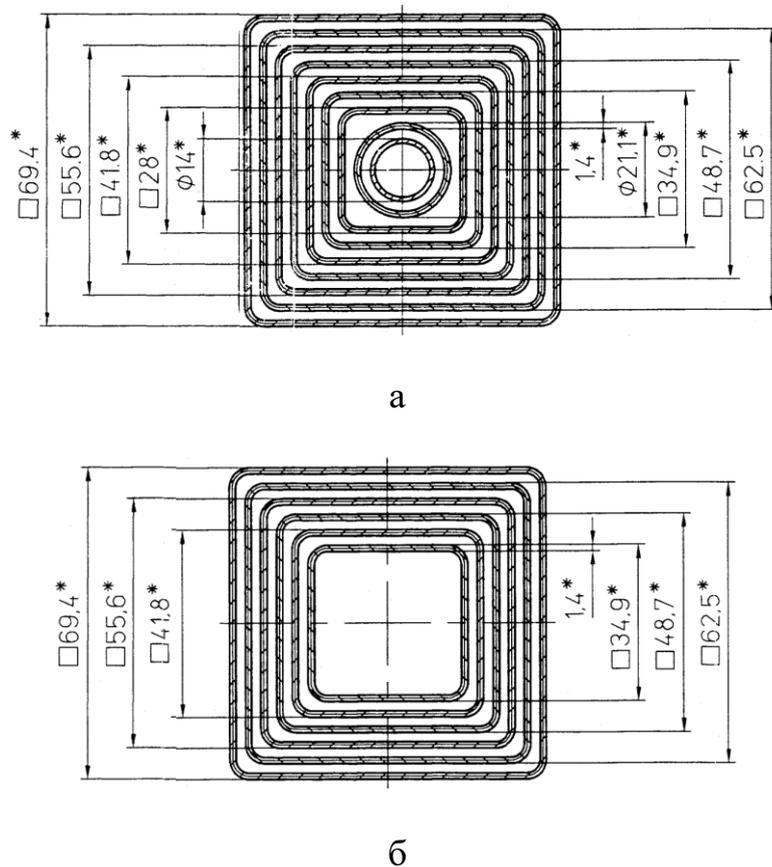


Рисунок 2.1 – Сечение ТВС типа ИРТ-3М: а – восьмитрубная;
б – шеститрубная

Штатная загрузка активной зоны реактора состоит из 11-ти восьмитрубных (8 тепловыделяющих элементов) и 9-ти шеститрубных (6 тепловыделяющих элементов) ТВС. Отражатель нейтронов выполнен из металлического бериллия,

имеет несимметричную форму и расположен по периметру активной зоны. Реактор имеет 10 горизонтальных и 15 вертикальных экспериментальных каналов диаметром от 42 до 180 мм. Наиболее интенсивные экспериментальные каналы расположены в центральной бериллиевой ловушке активной зоны. Среднегодовая продолжительность работы на номинальной мощности составляет 3000 часов. Картограмма активной зоны реактора ИРТ-Т представлена на рисунке 2.2.

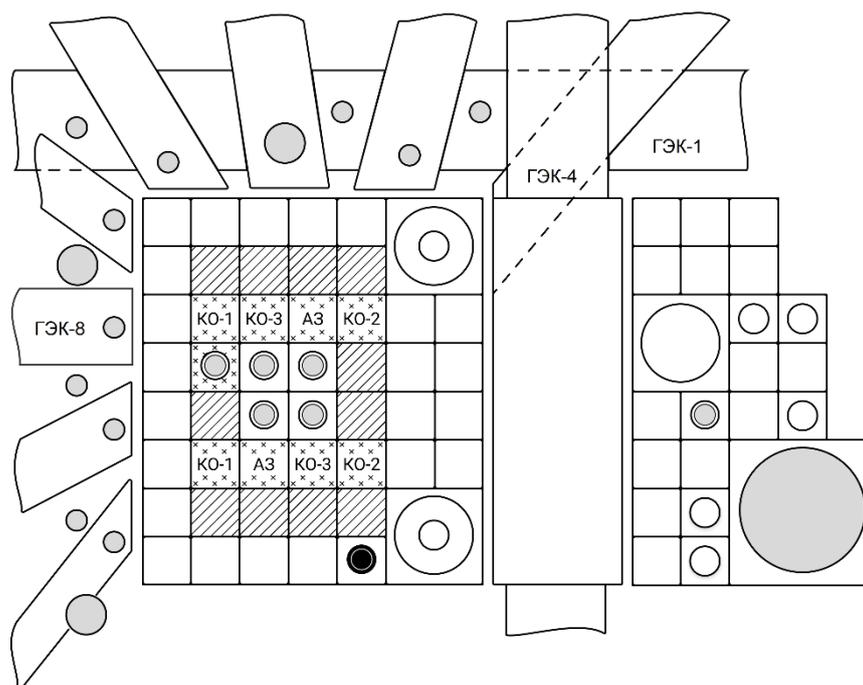


Рисунок 2.2 – Картограмма активной зоны реактора ИРТ-Т:

▨ — восьмитрубная ТВС; □ — бериллиевый блок; ▤ — шеститрубная ТВС с каналом для стержня СУЗ; ○ — вертикальный экспериментальный канал

Теплосъем с активной зоны реактора ИРТ-Т осуществляется системой охлаждения, состоящей из двух контуров. Первый – заполнен деминерализованной водой и отводит тепло, выделяемое в твэлах активной зоны. Вторым – открытым, где тепло, отводимое от первого контура рассеивается в атмосферу через водораспределительную систему градирни. Теплопередача тепла от первого контура ко второму осуществляется через теплообменные агрегаты ИРТ-1000 с поверхностью теплообмена 200 м². Центробежные насосы первого и второго контуров в режиме нормальной эксплуатации обеспечивают объемный расход теплоносителя равный 700 и 900 м³/ч, соответственно. Температура теплоносителя

на входе в активную зону составляет 40 – 45 °С, перепад температуры на активной зоне составляет 7,5 – 8,5 °С.

Функции измерения, контроля параметров, а также управление мощностью реактора реализованы на основе комплекса аппаратуры «МИРАЖ МБ», в состав которого входят подвески ионизационных камер ПИК-55 и ПИК-56. Основные функции регистрации комплекса:

- контроль относительной мощности по плотности потока нейтронов;
- контроль скорости изменения мощности;
- контроль перепада давления;
- контроль температуры теплоносителя на входе и выходе из активной зоны;
- контроль перемещения и положений РО СУЗ;
- обработка и хранение эксплуатационных показаний.

Аппаратурно-методическое обеспечение комплекса позволяет регистрировать параметры с погрешностью до $\pm 5\%$ и записывать экспериментальные данные с частотой до 10 Гц.

Регистрация параметров является неотъемлемой частью мониторинга состояния реактора. На основе перепада температуры теплоносителя определяется тепловая мощность и осуществляется корректировка нейтронной мощности реактора в процессе эксплуатации. Исходя из положений РО СУЗ и их интегральных характеристик экспериментально определяется запас реактивности, который представляет собой максимальную реактивность (2.1) активной зоны и характеризует возможность работы реактора на мощности с учетом температурных эффектов реактивности, процессов «отравления» и выгорания.

$$\rho = \frac{k_{eff} - 1}{k_{eff}} \cdot 100\%, \quad (2.1)$$

где,

k_{eff} – эффективный коэффициент размножения.

На практике (2.1) нормируется на эффективную долю запаздывающих нейтронов $\beta_{\text{эфф}}$ для удобства анализа и измерения реактивных характеристик активной зоны.

2.1.1 Расчетное сопровождения эксплуатации реактора ИРТ-Т с использованием программного средства MCU-PTR

Моделирование физических процессов, происходящих в активной зоне ядерного реактора, позволяет определять характеристики смешанного нейтронного и гамма-излучений, топлива, теплоносителя и других элементов. Экспериментальное определение параметров активной зоны реактора с учетом гетерогенной структуры сложно реализуема, что обусловлено высокими дозовыми нагрузками и ограниченным пространством для размещения соответствующих регистрирующих элементов и приборной базы.

Использование инструментов моделирования для определения характеристик действующего реактора представляет собой процесс расчетного сопровождения эксплуатации (РСЭ). Он направлен на оптимальное планирование работ, безопасную и эффективную эксплуатацию реактора. Область применения инженерных ПС ограничена сложностью и конструкционными особенностями реакторов, поэтому наибольшее распространение получили прецизионные ПС, реализующие метод Монте-Карло. Это обусловлено его высокой точностью и универсальностью для проведения нейтронно-физических расчетов.

Расчетное сопровождение эксплуатации и проводимых исследований на реакторе ИРТ-Т осуществляется с использованием ПС MCU-PTR. Программа MCU-PTR с библиотекой MDBPT50 разработана на основе модулей пакета MCU5 [83] и является развитием программ MCU-REA/1 и MCU-REA/2. Программы серии MCU предназначены для решения уравнения переноса излучения методом Монте-Карло для систем с произвольной трёхмерной геометрией на основе оцененных ядерных баз данных.

Для проведения расчетных обоснований на реакторе ИРТ-Т была разработана полномасштабная модель активной зоны (рисунок 2.3), включающая в

себя тепловыделяющие элементы, бериллиевые блоки отражателя, органы управления и экспериментальные каналы [84–87].

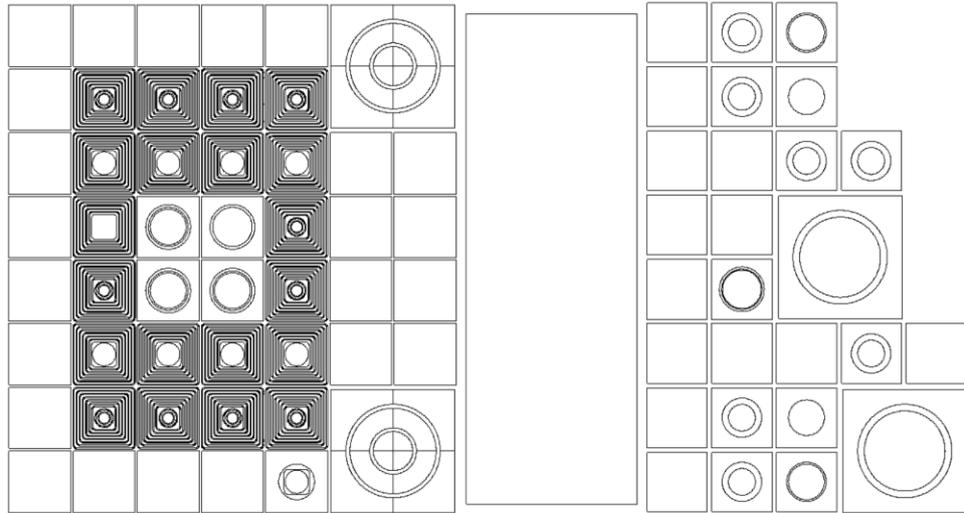


Рисунок 2.3 – Модель активной зоны реактора ИРТ-Т в ПС MCU-PTR

Расчетная модель топливной части ТВС выполнена в виде 6-ти материальных высотных слоев для определения изменения нуклидного состава топлива в результате выгорания. Модели РО СУЗ выполнены в виде 6 высотных и 3 радиальных слоев для учета выгорания изотопа В-10 в процессе топливных кампаний. Модели бериллиевых блоков отражателя содержат 6 высотных слоев, что позволяет оценивать влияние «отравления» бериллия на НФХ активной зоны с учетом высотной неравномерности распределения излучения.

В 2015 г. была проведена аттестация расчетной модели, которая осуществлялась на основе:

- сопоставления результатов расчетов с результатами тестовых задач;
- сопоставления расчетных результатов с эксплуатационными реакторными данными, включающими сведения о критических состояниях, запасе реактивности и энерговыработке с момента физического пуска в 1984 г и по 2014 г.

По результатам проведенной аттестации модели был получен паспорт программного средства, выданный экспертным советом по аттестации программных средств при Ростехнадзоре. Аттестованная модель активной зоны реактора ИРТ-Т используется для:

- определения НФХ исследовательского реактора ИРТ-Т или его фрагментов на основе метода Монте-Карло с учетом выгорания топлива, выгорания поглотителя в РО СУЗ, «отравления» бериллиевого отражателя и перемещения РО СУЗ;
- проведения расчетов при выборе и обосновании безопасности загрузок активной зоны реактора ИРТ-Т, включая обоснование безопасности экспериментальных устройств при их установке;
- проведения расчетов при обосновании требуемой плотности потока нейтронов в экспериментальных устройствах и каналах реактора;
- верификации инженерных программ нейтронно-физических расчетов исследовательских реакторов.

За период с 2015 г. по н.в. проведены работы, направленные на совершенствование модели, и включали: расчетно-экспериментальное уточнение и определение нейтронно-физических и теплофизических характеристик активной зоны реактора ИРТ-Т [88–91]. Текущий процесс РСЭ может быть описан общей схемой рисунка 2.4.

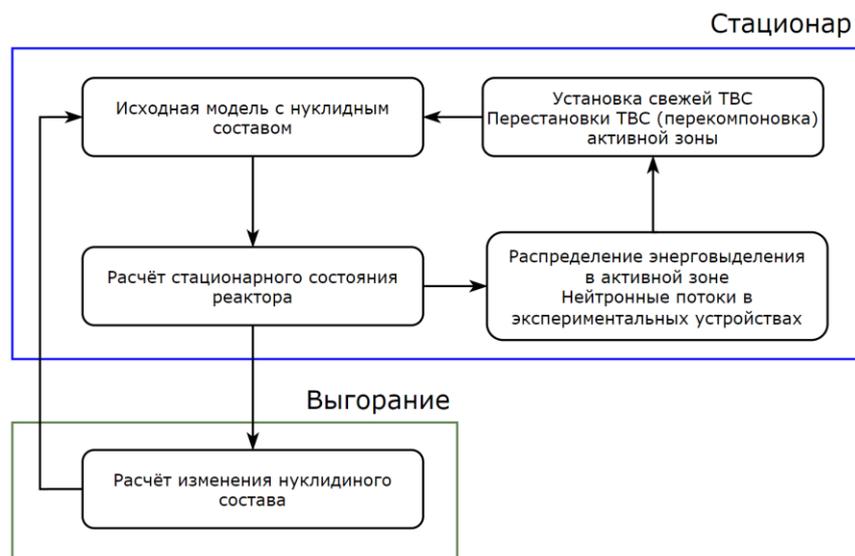


Рисунок 2.4 – Общая схема РСЭ реактора ИРТ-Т с использованием аттестованной модели в MCU-PTR

2.2 Предпосылки к оптимизации эксплуатационных характеристик активной зоны реактора ИРТ-Т

2.2.1 Неравномерность распределения энерговыделения

Эксплуатация реактора ИРТ-Т осуществляется в режиме частичных перегрузок топлива, при котором происходит выгрузка наиболее выгоревших ТВС. Количество перегружаемых ТВС определяется расчетным образом на этапе планирования работ и зависит от запаса реактивности реактора и плана-графика работы реактора, что влияет на продолжительность топливной кампании, которая варьируется от 35 до 65 эффективных суток.

Как правило, на место наиболее выгоревшей ТВС устанавливается «свежая», что оказывает влияние на характеристики нейтронного излучения в активной зоне и приводит к перераспределению энерговыделения в ячейках, которое сопровождается формированием локальных энергонапряженных участков. В таблицах 2.3, 2.4 представлен процесс изменения энерговыделения в топливных ячейках в результате перегрузочных работ некоторых кампаний реактора ИРТ-Т.

Таблица 2.3 – Изменение характера распределения энерговыделения по ячейкам активной при перегрузке в правой части активной зоны

	До перегрузки							
	Глубина выгорания, %				Энерговыделение, кВт			
	В	С	D	Е	В	С	D	Е
7	4,90	30,41	33,71	42,48	348,8	327,5	321,6	294,9
6	25,44	51,81	15,95	23,04	291,2	253,1	373,3	338,4
5	52,94			62,32	244,9			273,2
4	61,79			61,51	237,1			267,5
3	24,97	14,45	51,28	21,84	283,8	344,7	243,7	321,9
2	4,86	33,98	30,91	40,66	346,8	299,0	315,3	273,4
	После перегрузки							
	Глубина выгорания, %				Энерговыделение, кВт			
	В	С	D	Е	В	С	D	Е
7	4,90	30,41	33,71	42,48	291,6	286,0	300,1	292,9
6	25,44	51,81	15,95	23,04	244,0	225,3	361,0	348,6
5	52,94			0,00	207,1			524,3
4	61,79			0,00	200,4			510,3
3	24,97	14,45	51,28	21,84	235,3	307,7	236,2	330,3
2	4,86	33,98	30,91	40,66	283,3	255,1	288,1	272,3

В результате размещения «свежего» топлива в ячейках 4Е и 5Е происходит локальное увеличение энерговыделения более чем на 47 %, которое сопровождается перераспределением по остальным ячейкам и составляет в среднем 15 %. Максимальное энерговыделение до и после перегрузки составило 373 кВт и 524 кВт, соответственно, при средней мощности ТВС 300 кВт. Отношение максимальной мощности к средней до и после перегрузки составило 1,24 и 1,74, соответственно.

Таблица 2.4 – Изменение характера распределения энерговыделения по ячейкам активной в результате перегрузки в левой части активной зоны

	До перегрузки							
	Глубина выгорания, %				Энерговыделение, кВт			
	В	С	Д	Е	В	С	Д	Е
7	13,23	9,58	41,41	49,68	319,2	368,8	299,9	280,1
6	33,20	58,42	26,37	32,60	265,8	224,4	355,1	328,0
5	59,14			41,00	211,9			387,9
4	67,02			40,28	205,0			384,9
3	32,47	23,94	57,97	31,17	253,9	325,0	229,3	323,8
2	13,07	41,01	9,54	47,56	318,3	273,2	373,6	271,9

	После перегрузки							
	Глубина выгорания, %				Энерговыделение, кВт			
	В	С	Д	Е	В	С	Д	Е
7	13,23	9,58	41,41	49,68	314,3	347,3	268,7	242,2
6	33,20	58,42	26,37	32,60	267,5	219,2	324,6	285,9
5	0,00			41,00	383,6			339,5
4	0,00			40,28	430,7			336,9
3	32,47	23,94	57,97	31,17	262,2	323,8	211,0	281,3
2	13,07	41,01	9,54	47,56	323,1	261,6	339,7	237,0

При перегрузке в левой части активной зоны наблюдается локальное увеличение энерговыделения более чем на 52 % в ячейке 4В, что сопровождается изменением энергонапряженности других ячеек. Максимальное энерговыделение до и после перегрузки составило 388 кВт и 430 кВт, соответственно. Отношение максимальной мощности к средней до и после перегрузки составило 1,30 и 1,43, соответственно.

Как правило, «равномерность» распределения энерговыделения в активной зоне ядерных реакторов достигается за счет использования типовой схемы загрузки

топлива. Принимая во внимание форму бериллиевого отражателя, разный темп выгорания топлива в ячейках и большое разнообразие возможных комбинаций ТВС, использование типовой схемы загрузки / перегрузки топлива в активной зоне реактора ИРТ-Т не представляется возможным. Поэтому на практике снижение неравномерности распределения энерговыделения достигается путем разработки и реализации индивидуальной программы перегрузки и перестановок ТВС (профилирования).

Разработка такой программы базируется на проведении серии расчетов, в рамках которых оценивается изменение неравномерности распределения энерговыделения и запаса реактивности за счет перестановок ТВС в разные ячейки. Выбор ячеек осуществляется эмпирически и основывается на принципе: «свежие» ТВС в левую часть активной зоны, наиболее выгоревшие в правую. Количество возможных сценариев перестановок и комбинаций ТВС велико, поэтому рассматриваются только некоторые варианты, среди которых выбирается наиболее оптимальное решение, исходя из «равномерности» энерговыделения и величины запаса реактивности. Для подготовки одного сценария перестановочных операций затрачивается от 4 до 8 часов, включая модификацию расчетной модели, моделирование, обработку и анализ. Моделирование реализуется на многопоточной (до 50 потоков) серверной станции на базе Intel Xeon E5 2680.

Как можно видеть из значений таблиц 2.3, 2.4, активная зона реактора ИРТ-Т характеризуется высокой степенью неравномерности распределения энерговыделения. Это оказывает влияние на параметры излучения в экспериментальных устройствах, длительность топливной кампании и тепловые режимы работы топливных элементов. Изменение параметров нейтронного излучения относительно средних значений в некоторых каналах при перегрузках кампаний с правым и левым «перекосом» представлено на рисунке 2.5.

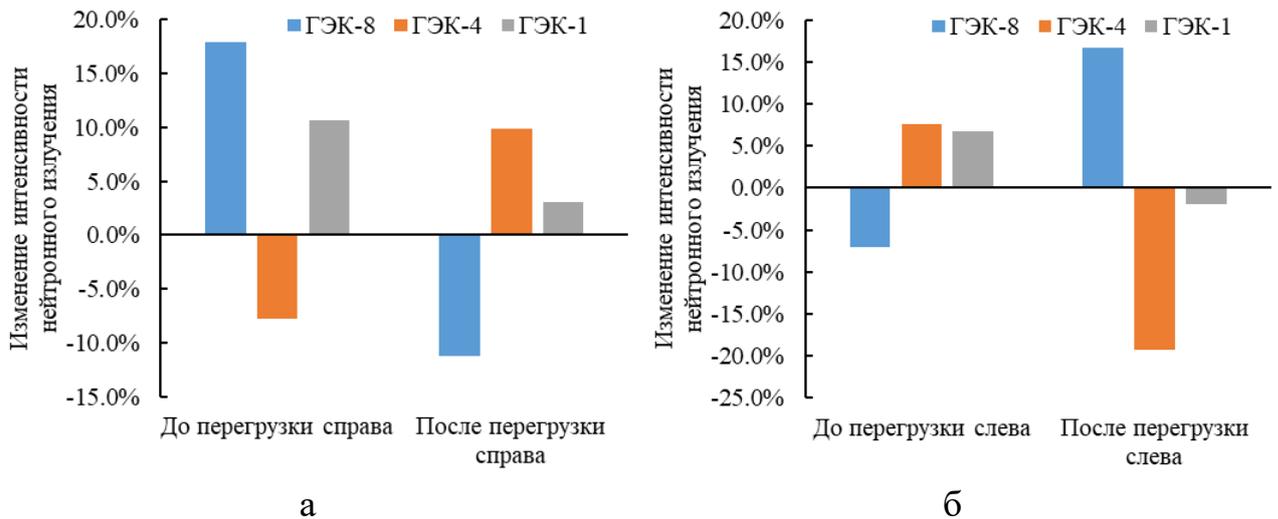


Рисунок 2.5 – Изменение интенсивности нейтронного излучения относительно средних значений в некоторых каналах реактора при перегрузке активной зоны

Из сравнительных данных рисунка 2.5 видно, что в результате перегрузок в левой и правой частях активной зоны, интенсивность нейтронного излучения варьируется. Относительное изменение плотности потока нейтронов в результате перегрузок может достигать 20–35 %, что обусловлено заменой отработавшего топлива на «свежее» вблизи рассматриваемых экспериментальных каналов. Средние значения интенсивности нейтронного излучения в каналах оценивались на основе расчетно-экспериментальных работ, включающих в себя: определение плотности потока нейтронов и активности нарабатываемых изотопов, а также оценку тепловой мощности реактора [92–94].

Таким образом, установка «свежего» топлива оказывает существенное влияние как на энергонапряженность ТВС, так и на параметры нейтронного излучения. Формирование условий, при которых энерговыделение в ячейках «равномерно», позволит уменьшить интервал изменения интенсивности нейтронного излучения в каналах, что обеспечит стабильность проведения экспериментальных исследований.

2.2.2 Детализация расчетной модели и возможности оптимизации процесса РСЭ

Несмотря на то, что ПС MCU-PTR позволяет проводить детальные нейтронно-физические исследования в активной зоне, общий подход к процессу РСЭ реактора ИРТ-Т требует оптимизации:

- не учитывается объемная неравномерность распределения энерговыделения в гетерогенной структуре топливных элементов – значения, характеризующие энергонапряженность ячеек занижены (таблицы 2.3, 2.4).

- расчет нескольких сценариев перестановок ТВС не позволяет судить об эффективности формируемой компоновки, что представляет собой проблему локального минимума.

Суммарное энерговыделение для картограмм таблиц 2.3, 2.4 составляет 6000 кВт, а значения в ячейках – интегральная мощность ТВС, которые характеризуют неравномерность распределения энерговыделения по сечению активной зоны. Следовательно, оценивается изменение (перераспределение) только между ячейками.

В мировой практике реакторной физики для определения неравномерности распределения энерговыделения в топливных элементах активной зоны используется объемный коэффициент неравномерности распределения энерговыделения (ОКНРЭ), который в общем случае определяется как отношение максимального значения к среднему:

$$K_V = \frac{\mathcal{E}_V^{\max}}{\mathcal{E}_V^{\text{aver}}} = K_h K_c = \frac{\mathcal{E}_h^{\max} \mathcal{E}_c^{\max}}{\mathcal{E}_h^{\text{aver}} \mathcal{E}_c^{\text{aver}}}, \quad (2.2)$$

где,

K_h, K_c – неравномерность распределения энерговыделения по высоте и сечению активной зоны, соответственно;

$\mathcal{E}_V^{\max}, \mathcal{E}_h^{\max}, \mathcal{E}_c^{\max}$ – максимальная энергонапряженность по объему, высоте и сечению активной зоны, соответственно;

$\mathcal{E}_V^{aver}, \mathcal{E}_h^{aver}, \mathcal{E}_c^{aver}$ – средняя энергонапряженность по объему, высоте и сечению активной зоны, соответственно.

Параметр ОКНРЭ показывает во сколько раз максимальное объемное энерговыделение (плотность энерговыделения) больше среднего по активной зоне. Отношение значений относительно среднего по координате (объему, высоте или ячейке) представляет собой массив отклонений от среднего, что характеризует неравномерность и в настоящей работе обозначается как КНРЭ (коэффициент неравномерности распределения энерговыделения).

Определение максимально энергонапряженного участка осуществляется исходя из значения ОКНРЭ и среднего значения энерговыделения в объеме активной зоны согласно:

$$\mathcal{E}_V^{\max} = K_V \cdot \mathcal{E}_V^{aver} \quad (2.3)$$

где,

$\mathcal{E}_V^{\max}, \mathcal{E}_V^{aver}$ – максимальное и среднее объемное значение энерговыделения, соответственно;

При рассмотрении топливных объектов (секторов) одного объема единицей измерения \mathcal{E}_V^{\max} и \mathcal{E}_V^{aver} может быть энерговыделение (Вт, кВт и т.д.), в ином случае – плотность энерговыделения (Вт/см³, кВт/см³ и т.д.).

Используя (2.2) к картограммам таблицы 2.4, можно оценить степень перераспределения энерговыделения между ячейками, а также величину ОКНРЭ с учетом высотного профиля. В таблице 2.5 приведены значения КНРЭ, а также «оптимальная» топливная компоновка, сформированная за счет перестановок.

Таблица 2.5 – Перераспределение энерговыделения в активной зоне с учетом K_V при перегрузке и перестановках

		До перегрузки				КНРЭ			
		Глубина выгорания, %							
		В	С	Д	Е	В	С	Д	Е
7		4,90	30,41	33,71	42,48	1,33	1,22	1,18	1,06
6		25,44	51,81	15,95	23,04	1,23	0,99	1,60	1,44
5		52,94			62,32	0,96			0,91
4		61,79			61,51	0,78			0,89
3		24,97	14,45	51,28	21,84	1,19	1,47	0,96	1,37
2		4,86	33,98	30,91	40,66	1,32	1,10	1,18	0,98

		После перегрузки				КНРЭ			
		Глубина выгорания, %							
		В	С	Д	Е	В	С	Д	Е
7		4,90	30,41	33,71	42,48	1,14	1,10	1,14	1,09
6		25,44	51,81	15,95	23,04	1,08	0,93	1,58	1,55
5		52,94			0,00	0,85			2,05
4		61,79			0,00	0,73			1,99
3		24,97	14,45	51,28	21,84	1,02	1,34	0,97	1,46
2		4,86	33,98	30,91	40,66	1,09	0,96	1,10	1,01

		После перестановок				КНРЭ			
		Глубина выгорания, %							
		В	С	Д	Е	В	С	Д	Е
7		4,90	0,00	33,71	42,48	1,41	1,68	1,30	1,21
6		25,44	51,81	15,95	23,04	1,24	1,06	1,76	1,59
5		52,94			30,41	0,99			1,72
4		61,79			30,91	0,82			1,68
3		24,97	14,45	51,28	21,84	1,17	1,54	1,06	1,53
2		4,86	33,98	0,00	40,66	1,36	1,14	1,63	1,14

ОКНРЭ до и после перегрузки составляет 1,60 и 2,05, соответственно. Полученные значения на 30 % и 19 % больше, чем приведенные в таблице 2.4, за счет учета высотной составляющей.

Запись (2.2) не учитывает гетерогенную структуру ТВС типа ИРТ-3М (рисунок 2.1): повышенная энергонапряженность в «скруглениях» и внешних твэлах, граничащих с бериллиевым отражателем. При увеличении степени детализации расчетной модели будет наблюдаться рост параметров K_V и \mathcal{E}_V^{\max} (2.3), которые играют важную роль при обосновании работы реактора в диапазоне допустимых значений.

Как правило, для этого рассматриваются параметры: тепловой поток W , (кВт/м²) и коэффициент запаса до кипения $K_{зан}$, определяемые в наиболее энергонапряженном участке активной зоны. Так, техническими условиями эксплуатации для реактора ИРТ-Т с ТВС ИРТ-3М установлен критический тепловой поток $W_{th}=0,8$ МВт/м² при котором достигается кризис теплообмена.

Средняя объемная плотность энерговыделения в активной зоне реактора ИРТ-Т при номинальной мощности 6000 кВт составляет $\mathcal{E}_V^{aver} = 1020$ МВт/м³. Тогда, исходя из эксплуатационных параметров реактора ИРТ-Т и связей между W , и \mathcal{E}_V , можно приближенно оценить предельно допустимые значения K_V и \mathcal{E}_V , при которых обеспечиваются безопасные условия эксплуатации:

$$\begin{aligned} \mathcal{E}_V^{th} &\approx \frac{W_{th} \cdot S}{P} = \frac{W_{th} \cdot A}{V}, \\ K_V^{th} &\approx \frac{W_{th} \cdot S}{\mathcal{E}_V^{aver} \cdot P} = \frac{W_{th} \cdot A}{\mathcal{E}_V^{aver} \cdot V}, \end{aligned} \quad (2.4)$$

где,

S – площадь сечения, м²;

P – периметр теплоотвода, м;

A – площадь поверхности, м²;

V – объем сектора, м³;

Оцененные K_V^{th} и \mathcal{E}_V^{th} , при которых достигается предельно допустимое значение W_{th} [95], составили $\approx 3,2$ и ≈ 3250 МВт/м³, соответственно.

Принимая во внимание выше упомянутое, необходимо отметить, что перестановки, осуществляемые с использованием кода MCU-PTR на основе модели без азимутального разбиения, не учитывают возможных локальных «всплесков» энерговыделения. Это ограничивает применимость текущего подхода к анализу предельных значений и профилированию активной зоны реактора ИРТ-Т на основе ОКНРЭ.

Для учета недостатков исходной модели предлагается детализировать геометрию ТВС за счет представления топливной части каждого твэла в виде

выгорающего материала и добавления азимутального разбиения, состоящего из 8-ми секторов (рисунок 2.6).

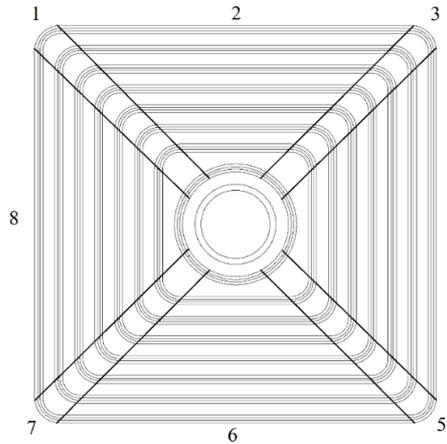


Рисунок 2.6 – Азимутальное разбиение ТВЭЛов восьмитрубной ТВС: 8 материалов на ТВЭЛ, 64 материала на высотный слой

С учетом разбиения ТВЭЛов и добавления азимутальных секторов, можно осуществить переход от упрощенной геометрии (2.2) к детальной (2.5):

$$K_V = K_h K_c K_{FA} = K_h K_c K_{fe} K_{azi} = \frac{\mathcal{E}_h^{\max} \mathcal{E}_c^{\max} \mathcal{E}_{fe}^{\max} \mathcal{E}_{azi}^{\max}}{\mathcal{E}_h^{\text{aver}} \mathcal{E}_c^{\text{aver}} \mathcal{E}_{fe}^{\text{aver}} \mathcal{E}_{azi}^{\text{aver}}}, \quad (2.5)$$

где,

K_{fe}, K_{azi} – КНРЭ по ТВЭлам и азимутальной составляющей;

$\mathcal{E}_{fe}^{\max}, \mathcal{E}_{azi}^{\max}$ – максимальное значение энерговыделения (плотности энерговыделения) по ТВЭлам и азимутальной составляющей;

$\mathcal{E}_{fe}^{\text{aver}}, \mathcal{E}_{azi}^{\text{aver}}$ – среднее значение энерговыделения (плотности энерговыделения) по ТВЭлам и азимутальной составляющей.

Переход от упрощенной (У) модели к детализированной (Д) для РСЭ и моделирования исследований не представляется возможным без нуклидного состава топлива. «Традиционный» расчет актуального состава топлива или переход от одной расчетной модели к другой включает в себя два подхода:

1. Постепенную замену исходной геометрии ТВС на новую, что позволяет получить нуклидный состав в каждом материальном слое новой геометрии, но требует повторного моделирования процесса выгорания согласно

эксплуатационным данным. Подход использовался на исследовательском реакторе ИР-8 (НИЦ «Курчатовский институт»), изменение расчетной модели осуществлялась при каждой перегрузке активной зоны, что заняло более 4-х лет (2011-2015 гг.) для полной замены геометрии всех ТВС и перехода на новую модель.

2. Полный цикл моделирования истории эксплуатации реактора, начиная с даты физического пуска по н.в., который был реализован в рамках аттестации модели ПС MCU-PTR на реакторе ИРТ-Т.

Оба подхода требуют больших вычислительных мощностей и времени на реализацию. При возникновении необходимости изменить степень детализации (разбиения) топлива потребуется проведение повторных расчетов для актуализации нуклидного состава, что снижает «гибкость» расчетных кодов.

Более того, при переходе на детальную модель происходит уменьшение геометрических объемов расчетных секторов (скругления и т.д.), что требует корректировки параметров моделирования для сохранения удовлетворительной точности результатов. Так, при переходе на модель, приведенную на рисунке 2.6, необходимо увеличение параметров моделирования в более чем в 150 раз для достижения погрешности на «скруглениях» не более 3–5 %, что накладывает сложности на процесс «ручного» подбора топливных загрузок.

С целью расширения существующих расчетных возможностей и оптимизации эксплуатационных характеристик активной зоны реактора ИРТ-Т в диссертационном исследовании предложен новый подход, основанный на интеграции метода Монте-Карло и машинного обучения, для:

- создания суррогатных моделей (эмуляторов);
- разработки метода формирования топливных загрузок, удовлетворяющих критериям «оптимальности».

Суррогатные модели позволят определять неравномерность распределения энерговыделения и запас реактивности активной зоны, что даст возможность ускорить «тяжелые» вычисления с сохранением исходной точности моделирования. В свою очередь, метод формирования схем загрузок позволит

перейти от «ручного» подбора схем загрузок к автоматизированному, базирующимся на анализе возможных компоновок и выборе наиболее оптимальных.

Для интеграции суррогатного моделирования в процесс РСЭ реактора ИРТ-Т предлагается использование двух прогнозных моделей (рисунок 2.7), что позволит определять основные эксплуатационные характеристики активной зоны реактора ИРТ-Т в зависимости от картограммы выгорания топлива и положений РО, а также количественно оценивать максимальную энергонапряженность в гетерогенной структуре ТВЭЛов (особенно для «свежих» ТВС).

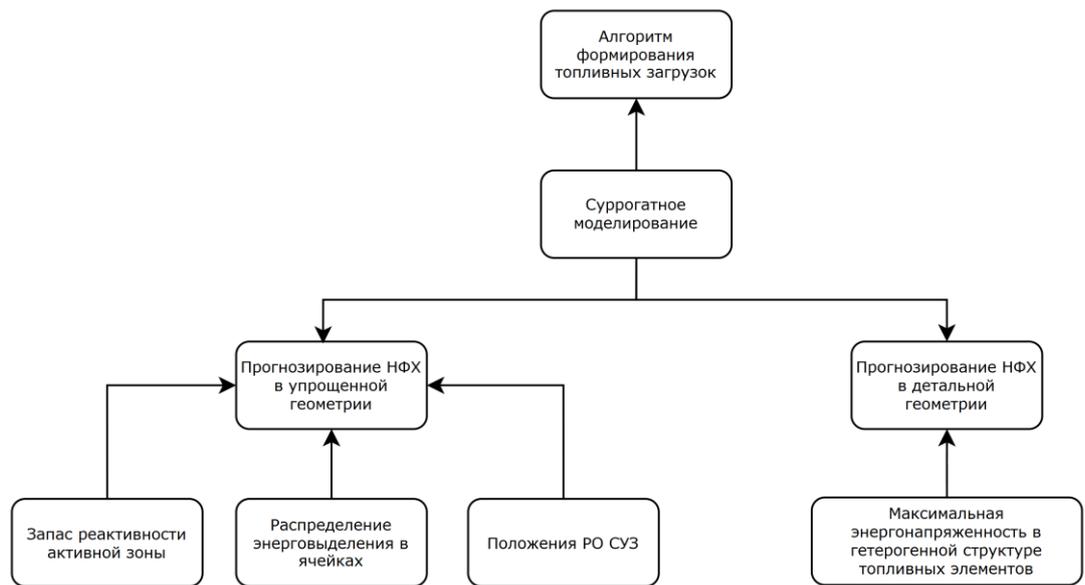


Рисунок 2.7 – Схема суррогатного моделирования в составе процесса РСЭ реактора ИРТ-Т

Для прогнозного описания состояний реальных загрузок необходимы актуальные данные, учитывающие выгорание и состав топлива в ТВС. В связи с этим, предлагается новый метод формирования нуклидного состава топлива, основанный на математической реконструкции ядерных концентраций с учетом неравномерности распределения глубины выгорания урана-235. Это делает возможным «восстановление» актуального состояния топливных загрузок без предварительных расчетов эксплуатационных циклов, что может быть применено для геометрии ТВС при любом уровне детализации.

2.3 Концепция реконструкции нуклидного состава топлива

В ПС MCU-PTR для расчета изменения нуклидного состава топлива используется библиотека констант, содержащая сведения о стабильных и радиоактивных нуклидах, что в совокупности с пошаговой схемой расчетов позволяет определять нуклидный состав и ядерные концентрации в топливе, а также их изменение в результате радиоактивного распада и ядерных реакций с высокой точностью в конечной геометрии.

Предлагаемый подход к реконструкции нуклидного состава топлива базируется на формировании приближенного (аппроксимационного) нуклидного состава исходя из неравномерности пространственного распределения глубины выгорания по аксиальной, поперечной и азимутальной составляющим.

Рассмотрим математическую формализацию концепции на основе модельной задачи, включающей несколько ТВС с одинаковым высотным разбиением, содержащим H слоев, но при разной глубине выгорания топлива, равной 0 % и 55 %.

Проведем модельный расчет каждой ТВС в «бесконечной» среде при фиксированной тепловой мощности $P = 300$ кВт. Так как, исходная глубина выгорания топлива существенно отличается, поддержание фиксированной P в каждой ТВС достигается за счет изменения плотности потока нейтронов Φ на некоторую величину, так чтобы выполнялось условие (2.6):

$$\begin{aligned}
 P &= K_f \sum_h^H R_h^{B_1} V_h = K_f \sum_h^H R_h^{B_2} V_h, \\
 P &= K_f \sum_h^H \Phi_h^{B_1} N_{nh}^{B_1} \sigma_f V_h = K_f \sum_h^H \Phi_h^{B_2} N_{nh}^{B_2} \sigma_f V_h,
 \end{aligned}
 \tag{2.6}$$

где,

B_1, B_2 – глубина выгорания ТВС, равная 0 %, 55 %, соответственно,

R – скорость реакции деления, делений \cdot с $^{-1}$ \cdot см $^{-3}$;

V – объем геометрической (расчетной) области;

N_n – количество урана-235, ядер;

σ_f – микроскопическое сечение реакции деления, см 2 ;

K_f – энергия, выделяющаяся в результате деления урана-235, Дж.

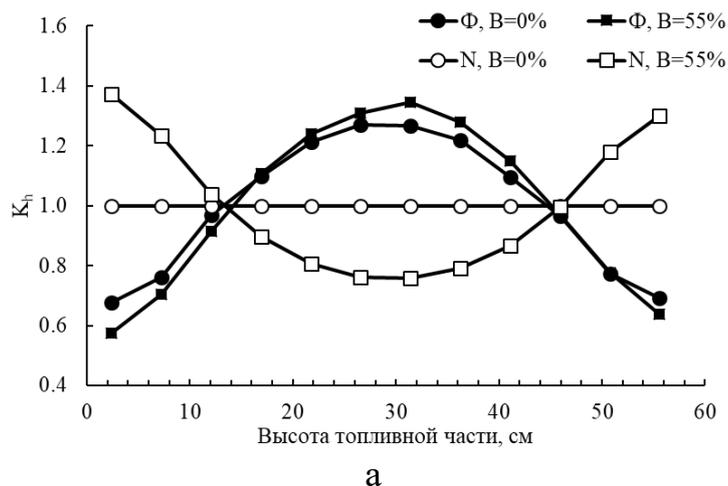
Связь между плотностью энерговыделения и скоростью реакции деления для использования в (2.6) представлена как: $\mathcal{E} = K_f R$, Вт/см³.

Значения плотности потока нейтронов и концентрации урана-235 в высотных слоях есть массивы $\Phi_H = [\Phi_1, \dots, \Phi_H]$ и $N_H = [N_1, \dots, N_H]$, соответственно. Тогда, значения скорости реакции представляют собой результирующий массив значений $R_H = [R_1, \dots, R_H]$, который описывает пространственное распределение энерговыделения по аксиальной составляющей, учитывает неравномерности распределения плотности потока нейтронов и концентрации урана-235. На рисунке 2.8 представлены стандартизированные (2.7) распределения плотности потока нейтронов, концентрации урана-235 и скорости реакции деления при разной глубине выгорания.

$$K_i = \frac{N_i}{\bar{N}_H}, i \in [1, \dots, H], \quad (2.7)$$

где,

K_i – значение, характеризующее отклонение (неравномерность) от среднего по массиву.



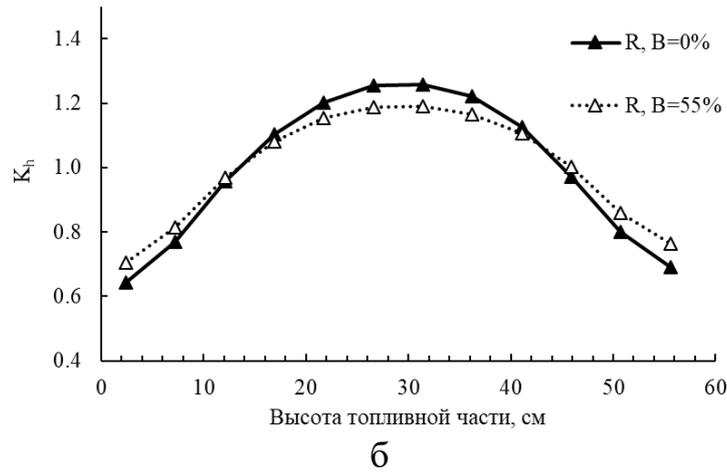


Рисунок 2.8 – Стандартизированные высотные распределения при разной глубине выгорания топлива: а – плотность потока нейтронов и концентрация урана-235; б – скорость реакции деления

Рассматривая Φ как коэффициент масштаба в каждом слое, определяемый в процессе моделирования НФХ, и на основе характеров распределения глубины выгорания топлива и нуклидного состава можно восстановить значения энерговыделения.

Из распределений рисунка 2.8б видно, что в результате выгорания топлива происходит «сглаживание» высотного профиля энерговыделения, то есть перераспределение энерговыделения от центра к периферии. При глубине выгорания ТВС до 55 % происходит снижение максимального значения до 10 % (с 1,28 до 1,16), которое сопровождается увеличением значений на периферии на ту же величину. Таким образом, любому значению B соответствует свое (приближенное) значение K^B , а совокупность K_i^B представляет собой $\mathbf{K}_H^B = [K_1^B, \dots, K_H^B]$, что является пространственным распределением при заданном B . В общем виде это может быть записано как:

$$\begin{bmatrix} K_1^1 & \dots & K_H^1 \\ \dots & \dots & \dots \\ K_1^M & \dots & K_H^M \end{bmatrix} = f \left(\begin{bmatrix} B^1 \\ \dots \\ B^M \end{bmatrix} \right), \quad (2.8)$$

$$\mathbf{K}_H^B = f(\mathbf{B})$$

Предложенная запись отражает некоторую функциональную зависимость в неявном виде. Строки и столбцы матрицы обладают свойствами (2.9), что полностью согласуется с распределениями рисунка 2.8.

$$\begin{aligned} K_1^j &\neq K_i^j, \quad i \in [2, \dots, H], \quad j \in [1, \dots, M], \\ \bar{K}_H^{B_j} &= 1, \quad j \in [1, \dots, M], \\ \sum_i^H K_i^j &= H, \quad i \in [1, \dots, H], \quad j \in [1, \dots, M] \end{aligned} \quad (2.9)$$

Для описания процесса пространственного распределения энерговыделения можно воспользоваться полиномиальной аппроксимацией и сформировать зависимости $\mathbf{K}_H^B = f(h, \mathbf{B})$, однако в этом случае будет описана только форма самой кривой, что не позволит корректно интерпретировать результаты.

Для функциональной формализации процесса перераспределения энерговыделения в результате выгорания топлива предлагается рассматривать изменение каждой пространственной компоненты как функцию от выгорания $K_{h_1}^B = f(h_1, B)$, ..., $K_{h_H}^B = f(h_H, B)$. Особенностью подхода является то, что при увеличении количества точек будет сохраняться свойство (2.9), т.е. будет изменяться количественный вклад компонент, но общий характер.

По аналогии с (2.8) можно представить зависимость ядерных концентраций нуклидов от глубины выгорания топлива как:

$$\begin{bmatrix} N^{1,1} & \dots & N^{S,1} \\ \dots & \dots & \dots \\ N^{1,M} & \dots & N^{S,M} \end{bmatrix} = f \left(\begin{bmatrix} B^1 \\ \dots \\ B^M \end{bmatrix} \right), \quad (2.10)$$

$$\mathbf{N} = f(\mathbf{B}),$$

где,

S – количество нуклидов в топливе.

N – ядерная концентрация, см⁻³;

Из (2.8) и (2.10) следует, что в рамках рассматриваемой задачи, реконструкция материального состава ТВС по высотной составляющей h может быть описана исходя из закономерностей изменения профиля высотного

распределения глубины выгорания и ядерных концентраций нуклидов в топливе, так что:

$$\begin{aligned} \mathbf{V}_H &= f(\mathbf{H}, B_{av}) = B_{av} \mathbf{K}_H^{B_{av}}, \\ \mathbf{N}_H &= f(\mathbf{V}_H) \end{aligned} \quad (2.11)$$

где,

B_{av} – среднее значение глубины выгорания в ТВС, %;

\mathbf{V}_H – массив, описывающий характер высотного распределения глубины выгорания при B_{av} ,

\mathbf{N}_H – двумерный массив, содержащий ядерные концентрации нуклидов с учетом значений глубины выгорания в высотных слоях.

Массив \mathbf{N}_H содержит синтетический нуклидный состав топлива, учитывающий неравномерность пространственного распределения выгорания в высотных слоях. Определение аналогичных пространственных распределений относительно ТВЭЛов и азимутальной составляющей позволит осуществить детальную реконструкцию материального состава всей ТВС.

Для подтверждения применимости предложенного подхода к реконструкции материального состава топлива в гетерогенной активной зоне требуется:

- моделирование НФХ всей активной зоны с использованием детализированной геометрии ТВС (высотные, потвэльные и азимутальные слои);
- подготовка исходных данных и установление закономерностей формирования пространственного распределения выгорания (2.8);
- формирование исходных данных и установление зависимостей (2.10);
- разработка алгоритма генерации нуклидного состава топлива;
- проведение бенчмарков (кросс-верификации) на основе референтной (аттестованной) модели и экспериментальных данных реактора ИРТ-Т.

2.4 Формирование пространственных распределений выгорания в топливных элементах

Моделирование НФХ относительно всех ячеек активной зоны с использованием детализированных моделей ТВС обусловлено:

- отсутствием симметричных участков (ТВС и блоки отражателя);
- повышенной напряженностью твэлов ТВС, граничащих с бериллиевым отражателем;
- использованием РО СУЗ для компенсации избыточной реактивности в активной зоне, что приводит к «искажению» профиля распределения нейтронного излучения;
- высокой неоднородностью распределения энерговыделения по ячейкам активной зоны (таблица 2.5);
- эффектом «отравления» бериллиевого отражателя, оказывающим влияние на запас реактивности активной зоны.

Для установления и подробного описания закономерностей распределения выгорания необходим высокий уровень детализации всех топливных элементов ТВС, поэтому в рамках задачи предлагается использовать специальную модель, включающую следующие геометрические разбиения:

- 15 высотных материальных слоев, что позволит установить зависимости относительно аксиальной составляющей h для восьмитрубных и шеститрубных ТВС с учетом положений РО СУЗ в активной зоне;
- 20 материальных слоев на один твэл, что позволит установить зависимости относительно твэлов (fe) и по азимутальной составляющей (azi) (рисунок 2.9).

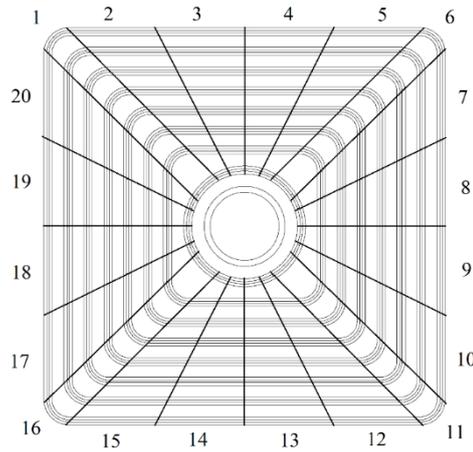


Рисунок 2.9 – Азимутальное разбиение твэлов восьмитрубной ТВС:
20 материалов на твэл, 160 материалов на высотный слой

В этом случае суммарное количество топливных материалов на одну ТВС составляет 2400 и 1800 для восьмитрубной и шеститрубной, соответственно.

С учетом предложенной детализации общая формула для реконструкции нуклидного состава ТВС в дискретном виде может быть получена за счет незначительной модификации (2.11):

$$\begin{aligned} \mathbf{V}_{H,FE,AZI}^L &= B_{av} \mathbf{K}_H^{B_{av}} \mathbf{K}_{FE}^{B_{av}} \mathbf{K}_{AZI}^{B_{av}}, \\ \mathbf{N}_{H,FE,AZI}^T &= \mathbf{N}^S \mathbf{V}_{H,FE,AZI}^L, \end{aligned} \quad (2.12)$$

где,

FE – количество твэлов;

AZI – количество материальных слоев на один твэл;

$L = H \cdot FE \cdot AZI$ – размер выходного массива значений глубины выгорания, то есть суммарное количество материальных слоев в ТВС;

$T = S \cdot L$ – размер выходного массива ядерных концентраций, то есть суммарное количество нуклидов во всех материалах ТВС;

Моделирование НФХ всей активной зоны с детализированными ТВС требует больших вычислительных мощностей, что обусловлено набором статистики в каждом топливном слое. Для достижения глубины выгорания каждой ТВС не менее 75 % требуется проведение серии расчетов по типу «выгорание-перегрузка», где на месте наиболее выгоревших ТВС устанавливаются «свежие».

В качестве исходного состояния активной зоны для проведения расчетов была выбрана «свежая» топливная загрузка при «среднем» положении РО СУЗ в активной зоне 25 см, что соответствует среднему положению РО за топливную кампанию. Условия моделирования подбирались таким образом, чтобы статистическая ошибка определения функционалов не превышала 5 % для каждого слоя.

По завершении расчетных циклов осуществлялась программная обработка файлов, описывающих состояние активной зоны, и формировались выходные матрицы значений с шагом по выгоранию не более 2,5 %, которые:

- содержат ядерные концентрации стабильных и радиоактивных нуклидов (2.10), образующихся в результате деления и трансмутации;
- содержат значения глубины выгорания урана-235 относительно высотного, потвэльного и азимутальной координат (2.13).

Для реализации процедуры реконструкции нуклидного состава топлива было отобрано более 140 нуклидов при пороговом выходе $1 \cdot 10^{-4}$ %, для каждого из которых формировались массивы (2.10). Зависимости выхода некоторых делящихся и воспроизводящих ядер от глубины выгорания урана-235 приведены на рисунке 2.10.

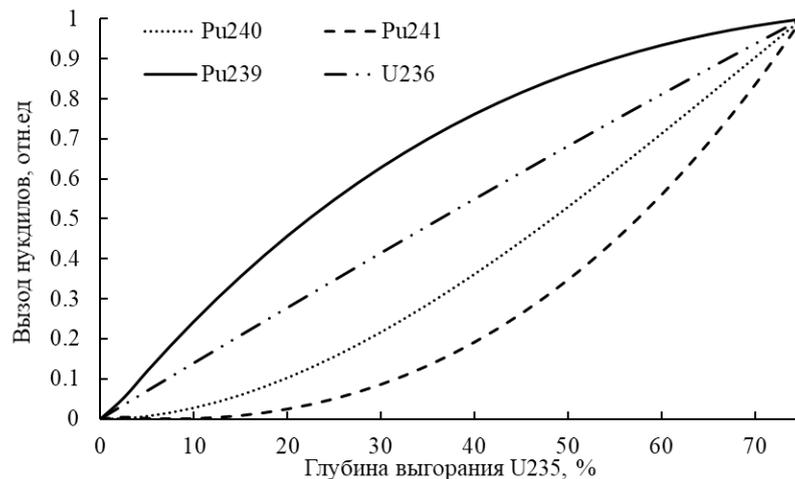


Рисунок 2.10 – Выход некоторых делящихся и воспроизводящих ядер в зависимости от глубины выгорания U-235

$$\mathbf{B}_{FA}^{h,fe,azi} = \begin{bmatrix} B^{1,1} & \dots & B^{O,1} \\ \dots & \dots & \dots \\ B^{1,M} & \dots & B^{O,M} \end{bmatrix}, \quad (2.13)$$

где,

FA – номер ячейки активной зоны;

O – количество секторов в зависимости от рассматриваемой пространственной координаты (h, fe, azi).

Нормировка строк матрицы на среднее значение в строке позволяет перейти к общему виду (2.8) для всех пространственных координат и ТВС.

Далее на основе подготовленных данных были рассмотрены профили пространственных распределений глубины выгорания и их изменения. На рисунке 2.11 представлена высотная неравномерность распределения глубины выгорания для некоторых топливных ячеек активной зоны реактора ИРТ-Т при $B = 2,5\%$ («свежее» топливо).

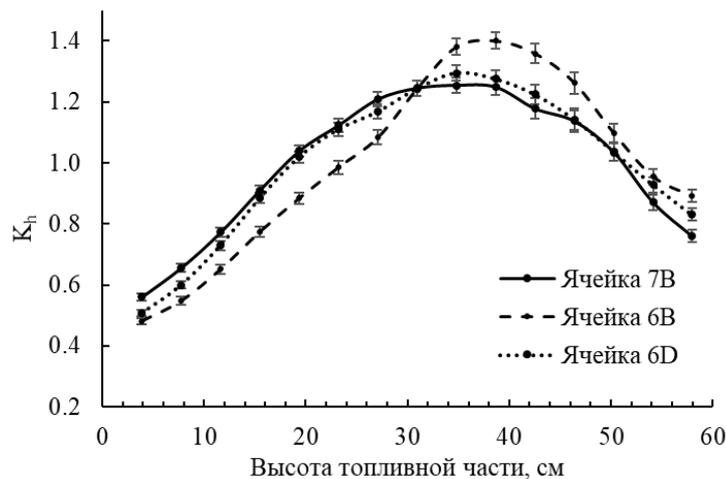


Рисунок 2.11 – Высотное распределение глубины выгорания в ячейках активной зоны: 7В – восьмитрубная; 6В – шеститрубная с РО СУЗ; 6Д - шеститрубная с стержнями АЗ СУЗ

Можно видеть, что значение коэффициента высотной неравномерности распределения глубины выгорания K_h для ячеек 7В, 6В и 6Д составляет 1,27, 1,29 и 1,41, соответственно. Характер распределений имеет существенные отличия, следовательно, процесс «сглаживания» в результате выгорания топлива будет

различаться. Так, на рисунке 2.12 представлены изменения неравномерности распределения глубины выгорания (2.8) в центральном (K_8) и периферийном (K_I) высотных слоях (расчетных точках) в результате выгорания ТВС.

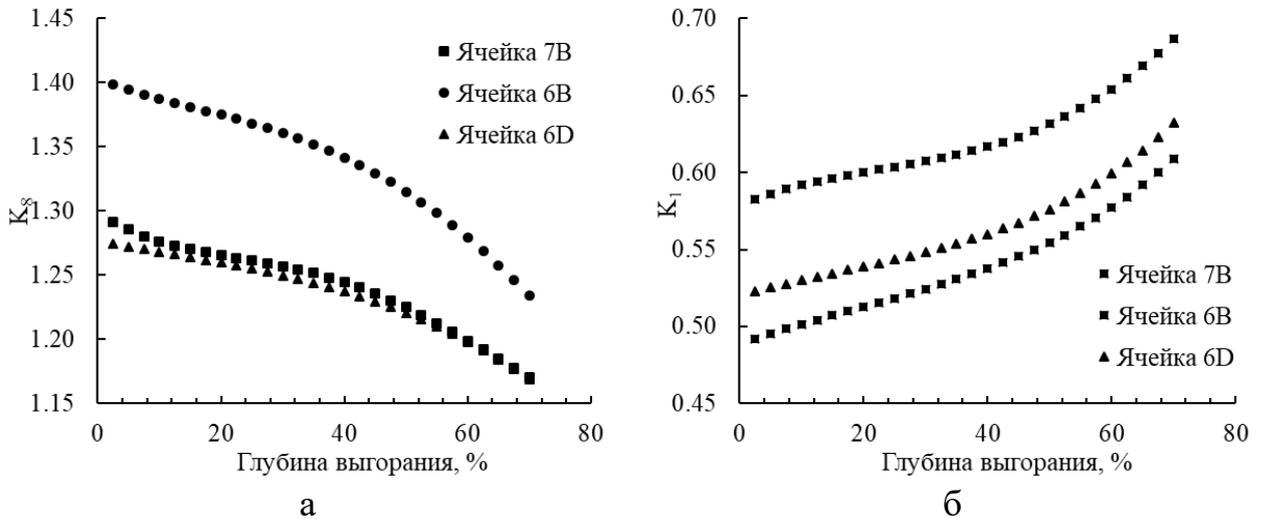


Рисунок 2.12 – Изменение неравномерности распределения глубины выгорания в ячейках активной зоны в результате выгорания топлива: а – центральный высотный слой (K_8); б – периферийный высотный слой (K_I)

Из распределений рисунка 2.11 видно, что монотонная убыль K_8 (и другим центральным участкам) компенсируется за счет периферии K_I . Представим процесс выгорания и перераспределения в виде суммы компонент:

$$K^i = A(B^i) + C(B^i), \quad (2.14)$$

где,

$A(B)$ – компонента потери энергонапряженности сектора ввиду процесса выгорания топлива;

$C(B)$ – компонента прироста энергонапряженности в рассматриваемой ячейке ввиду перераспределения энерговыделения.

Следовательно, для центральных ячеек характерно преобладание первой компоненты, характеризующей убыль, а для периферийных – второй. Рассмотрим этот процесс относительно физических особенностей взаимодействия нейтронного излучения с веществом, которые с удовлетворительной точностью описываются экспоненциальными полуэмпирическими зависимостями [96]. Тогда, представим (2.14) в виде суммы двух экспонент с некоторыми коэффициентами.

$$K^i = K_{B_0}^i (A_1 \exp(-a_1^i B^i) + A_2 \exp(a_2^i B^i)), \quad (2.15)$$

где,

$K_{B_0}^i$ – энергонапряженность для «свежего» топлива в i -й ячейке;

A_1, A_2 – коэффициенты масштаба;

a_1^i – коэффициент потери энергонапряженности на единицу B в i -й ячейке, $\%^{-1}$;

a_2 – коэффициент прироста на единицу B в i -й ячейке ввиду большей скорости выгорания в других пространственных участках $\%^{-1}$.

На рисунке 2.13 представлены результаты аппроксимации высотных участков (коэффициентов) K_7 и K_8 ячеек 7В и 6В с помощью (2.15) по методу наименьших квадратов.

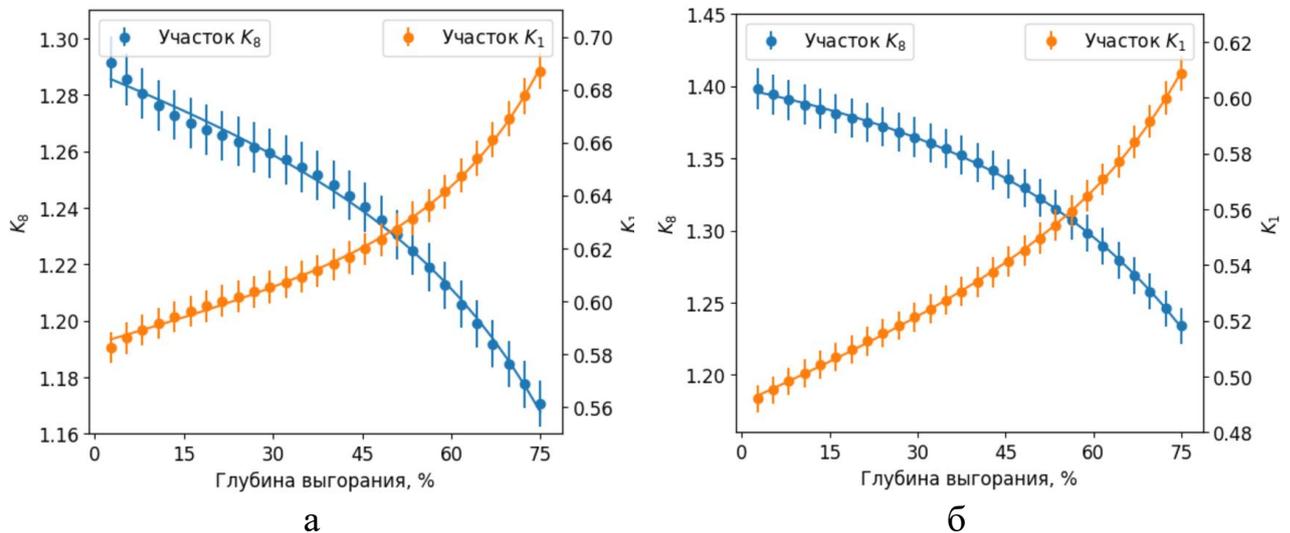


Рисунок 2.13 – Аппроксимация неравномерности распределения глубины выгорания в центральных и периферийных высотных участках:

а – ячейка 7В; б – ячейка 6В

Из распределений следует, что предложенный подход позволяет описать изменения коэффициентов в результате выгорания топлива. Общая точность аппроксимации для каждого высотного участка по коэффициенту детерминации R^2 составила не менее 99 %. Это позволяет перейти от дискретных массивов, характеризующих высотное распределение, к непрерывным зависимостям $\mathbf{K}_{\mathbf{H}}^{\mathbf{B}} = f(\mathbf{H}, B)$.

По аналогии с высотным распределением определялись профили распределения глубины выгорания по твэлам и азимутальным секторам, а также оценивалась применимость (2.15) в качестве аппроксимирующей функции. На рисунке 2.14 представлены распределения глубины выгорания по твэлам (от внешнего к внутреннему) для некоторых ячеек активной зоны реактора ИРТ-Т.

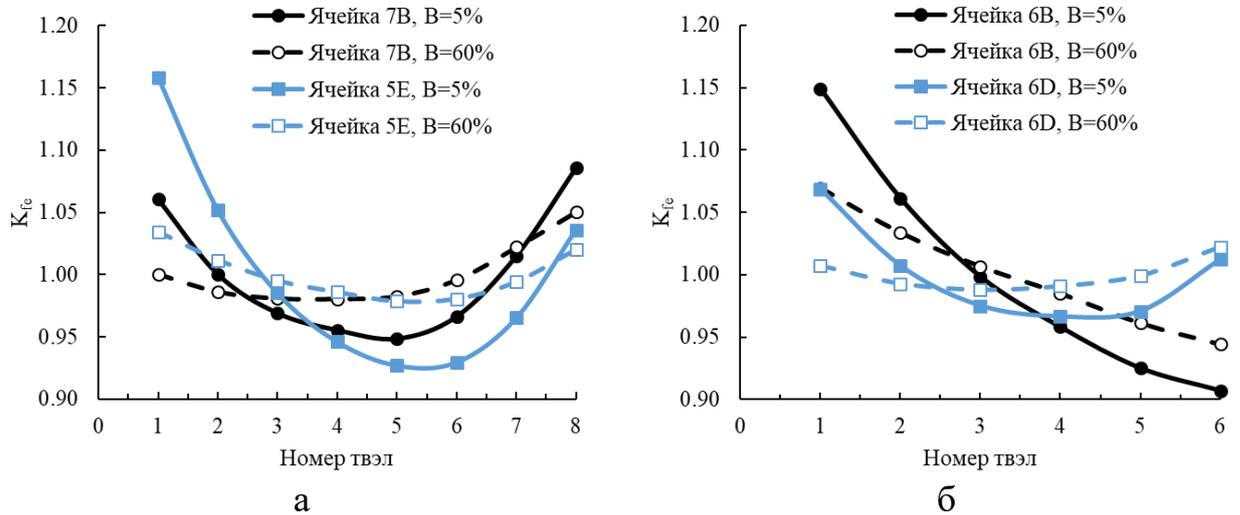


Рисунок 2.14 – Стандартизированные распределения глубины выгорания по твэлам некоторых ТВС: а – центральные и периферийные восьмитрубные ТВС; б – шеститрубные ТВС с РО СУЗ и без

Значения K_{fe} для периферийных восьмитрубных ТВС составляют 1,12 и 1,01 при глубине выгорания 5 % и 60 % соответственно. Максимальное и среднее изменения K_{fe} по твэлам составляет 10,0 % и 5,1 %, соответственно. Значения K_{fe} для центральных восьмитрубных ТВС составляют 1,07 и 1,05 при глубине выгорания 5 % и 60 % соответственно. Максимальное и среднее изменения K_{fe} по твэлам составляет 6,9 % и 4,3 %, соответственно. Как можно видеть, характер распределения между твэлами центральной и периферийной ТВС (рисунок 2.14а) отличаются, что обусловлено разницей в энергонапряженности твэлов.

Для шеститрубных ТВС с РО СУЗ значения K_{fe} составляют 1,16 и 1,06 при глубине выгорания 5 % и 60 % соответственно. Максимальное и среднее изменения K_{fe} по твэлам составляет 8,8 % и 4,2 %, соответственно. Для шеститрубных ТВС без РО СУЗ значения K_{fe} составляют 1,06 и 1,01 при глубине выгорания 5 % и 60 % соответственно. Максимальное и среднее изменения K_{fe} по твэлам составляет 4,9 %

и 3,4 %, соответственно. Поглощающие свойства РО СУЗ оказывают существенное влияние на энергонапряженность и скорость выгорания топлива в ТВЭлах, что обуславливает отличие форм кривых рисунка 2.14б.

Для корректного описания пространственного распределения глубины выгорания между ТВЭлами необходимо учитывать особенности каждой ячейки активной зоны, то есть требуется рассматриваться 20 функциональных зависимостей $K_{FE}^B = f(FE, B)$.

Исходя из формы распределений рисунка 2.14 нетрудно предположить, что неравномерность распределения глубины выгорания в каждом ТВЭле будет иметь свой характер. Пространственные распределения для первых ТВЭлов некоторых ячеек активной зоны представлены на рисунке 2.15.

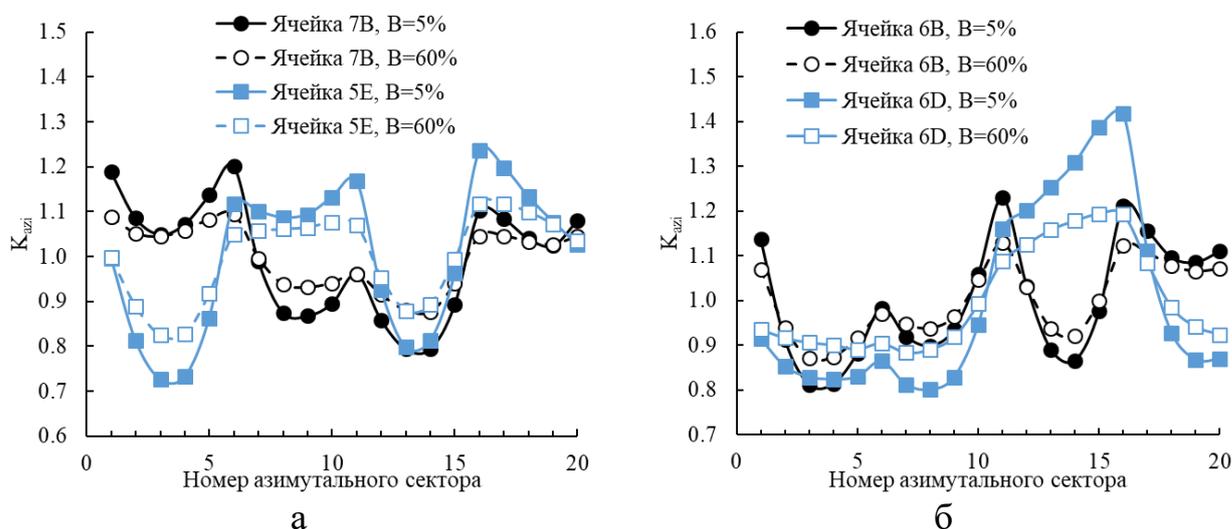


Рисунок 2.15 – Стандартизированные распределения глубины выгорания в первых ТВЭлах некоторых ячеек: а – ячейки 7В и 5Е;

б – ячейки 6В и 6Д

Из рисунка 2.15 видно, что в зависимости от рассматриваемой восьмитрубной ТВС присутствует существенная разница между пространственными распределениями глубины выгорания. Для периферийных ТВС значения K_{azi} составляют 1,20 и 1,09 при глубине выгорания 5 % и 60 % соответственно. Для центральных ТВС значения K_{azi} составляют 1,24 и 1,10 при глубине выгорания 5 % и 60 % соответственно. Максимальная и средняя относительная разница между распределениями в ТВС составляет 46,1 % и 16,2 %, соответственно.

соответственно, что обусловлено высокой энергонапряженностью скруглений ТВЭЛОВ (сектор №1, 6 ячейки 7В, сектор №11, 16 ячейки 5Е).

Для шеститрубных ТВС так же присутствует существенная разница между пространственными распределениями глубины выгорания. Для ТВС с РО СУЗ значения K_{azi} составляют 1,26 и 1,11 при глубине выгорания 5 % и 60 % соответственно. Для ТВС без РО СУЗ значения K_{azi} составляют 1,49 и 1,22 при глубине выгорания 5 % и 60 % соответственно. Максимальная и средняя относительная разница между распределениями составляет 38,6 % и 23,4 %, соответственно, что обусловлено высокой энергонапряженностью скругленных секторов в ТВЭлах, расположенных вблизи бериллиевых блоков, а также влиянием поглощающего стержня (сектор №11 ячейки 6В, сектор №11, 16 ячейки 6D).

Поэтому для корректного описания азимутальных пространственных зависимостей необходимо рассматривать каждый ТВЭЛ независимо, что требует установления не менее 142 функциональных зависимостей $\mathbf{K}_{AZI}^B = f(AZI, B)$.

На рисунке 2.16 представлены результаты функционального описания «ТВЭЛЬНЫХ» и азимутальных распределений неравномерности выгорания в некоторых участках ячейки 7В.

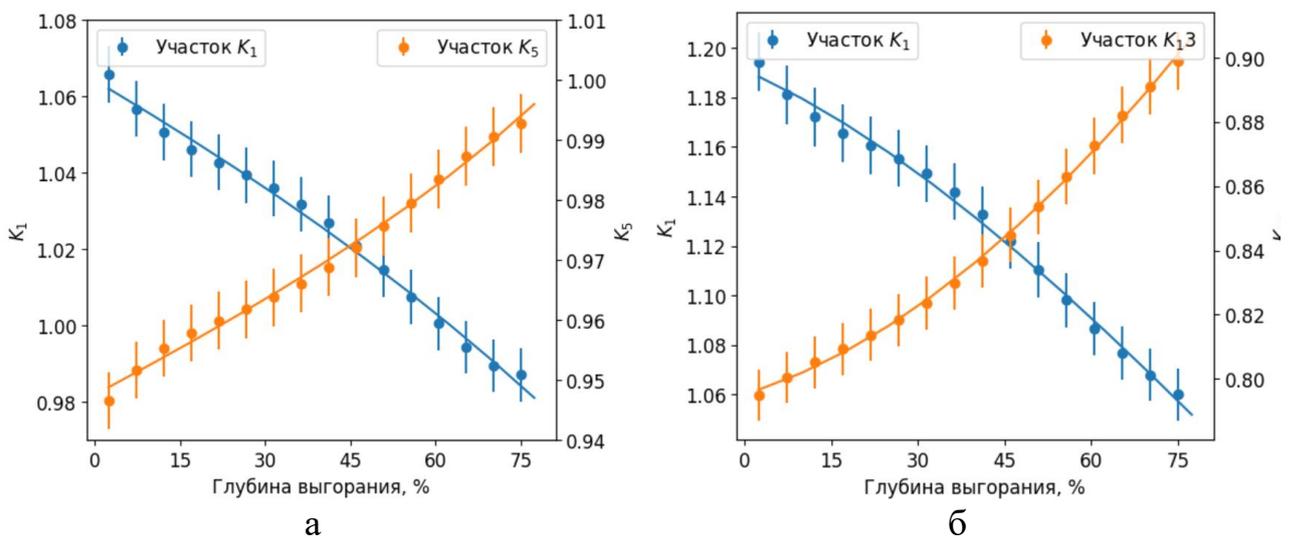


Рисунок 2.16 – Аппроксимация неравномерности распределения глубины выгорания в ячейке 7В: а – ТВЭлы K_1 и K_5 ; б – азимутальные участки K_1 и K_{13} первого ТВЭла

Из распределений рисунков 2.14 и 2.15 видно, что значение коэффициента неравномерности значительно ниже, чем по высотной составляющей и не превышает 1,20. Следовательно, «скорость» перераспределения относительно пространственных участков (ТВЭЛОВ) ниже, что обуславливает характер кривых рисунка 2.16. Предложенная запись (2.11) позволяет описывать особенности изменения неравномерности выгорания относительно ТВЭЛОВ и азимутальных участков. Общая точность аппроксимации составила не менее 98 % для всех рассматриваемых ячеек и секторов.

Таким образом, общее количество функциональных зависимостей, необходимое для описания пространственных распределений глубины выгорания относительно высотной, потвальной и азимутальной координат для всей активной зоны реактора ИРТ-Т составило 165.

В исходном виде сформированные зависимости описывают пространственные распределения только для фиксированной геометрии модели, содержащей 16 высотных слоев и 20 азимутальных слоев в каждом ТВэле. При изменении дискретности геометрии ТВС вклад отдельных коэффициентов по пространственным координатам будет отличен от приведенных. Чтобы использовать рассмотренный подход для геометрии с любым пространственным разбиением предлагается использовать сглаживание по методу наименьших квадратов на основе одномерной сплайн-функции (2.16).

$$S(x) = \sum_{j=0}^{n-1} c_j BS_{j,k,t}(x), \quad (2.16)$$

где,

x – пространственная координата;

c – коэффициенты сплайна;

BS – В-сплайн базовая функция;

k – степень сплайна;

t – количество узлов сплайна.

Для исходных пространственных распределений, сформированных согласно (2.15), возможно совершить переход другой дискретности на основе

интерполяции так, что для иного пространственного разбиения будут сохраняться свойства (2.9). На рисунке 2.17 представлен пример перехода от 15-ти высотных слоев к упрощенному разбиению с 6-ю слоями.

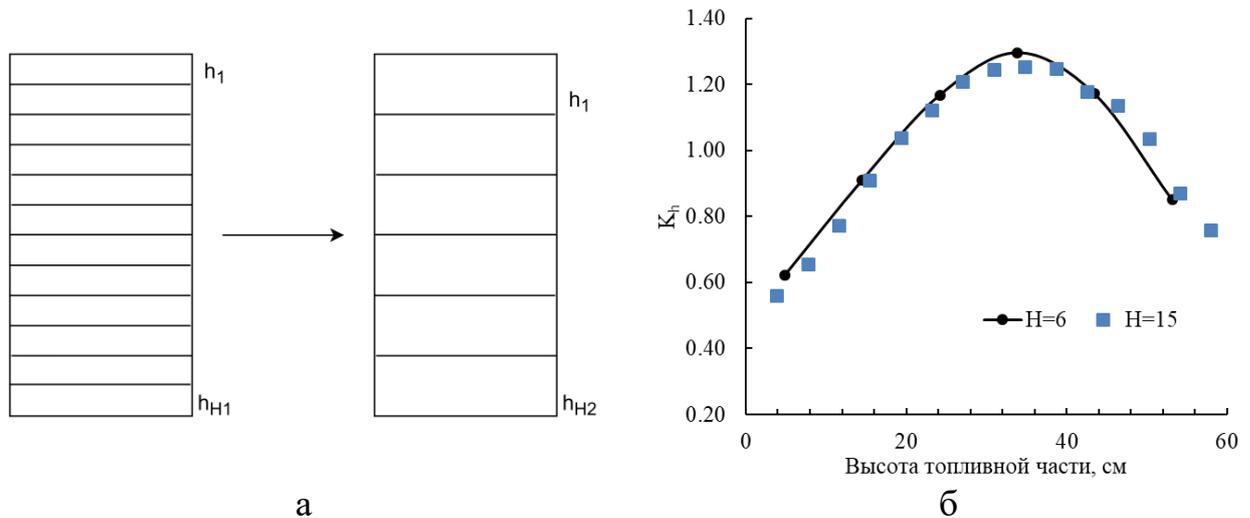


Рисунок 2.17 – Переход от детального высотного разбиения к упрощенному: а – иллюстрация перехода; б – высотные распределения

Можно видеть, что полученные форма кривой и численные значения соответствуют исходному распределению, что не накладывает ограничений на применение метода и позволяет переходить от одного геометрического разбиения к другому.

Таким образом, на основе специальной расчетной модели с высокой степенью детализации были сформированы массивы, содержащие расчетные данные ядерных концентраций нуклидов и распределения глубины выгорания по секторам ТВС. На основе исходных данных были установлены функциональные закономерности пространственного распределения глубины выгорания для всех топливных ячеек активной зоны реактора ИРТ-Т. Предложен способ сглаживания на основе сплайн-функции для адаптации закономерностей под геометрию ТВС с произвольным разбиением. Общее описание алгоритма реконструкции пространственного распределения глубины выгорания представлено в виде псевдокода в таблице 2.6.

Таблица 2.6 – Описание алгоритма реконструкции пространственного распределения глубины выгорания

Вход:

COREB[CB_1, \dots, CB_{FA}] картограмма выгорания активной зоны с $FA=20$,
 $distrs_h$, $distrs_fe$, $distrs_azi$ – пространственные зависимости по каждой координате в формате пары «имя атрибута-значение»

Выход:

массив **COREU** размерностью (FA, L) и количеством элементов $C = FA \cdot L$

procedure COREDISTR(**COREB**, **H**, **FE**, **AZI**)

declare B_C [1:FA, 1:L]

declare $num = 1$

for each B , $fa=1$ of **COREB**, FA :

$K_H = distrs_h(H, B)$

$B_H = B \cdot K_H$

for each B_h of B_H :

$K_{FE} = distrs_fe(FE, B_h)$

$B_{FE} = B_h \cdot K_{FE}$

for each B_{fe} of B_{FE} :

$K_{AZI} = distrs_azi(AZI, B_{fe})$

$B_{AZI} = B_{fe} \cdot K_{AZI}$

for each B_{azi} of B_{AZI} :

$B_C[fa][num] = B_{azi}$

$num ++$

end for

end for

end for

end for

end procedure

Формируемый выходной массив, содержащий значения глубины выгорания, используется для генерации ядерных концентраций и формирования нуклидного состава топлива.

2.5 Верификация и валидация метода реконструкции состава топлива

Для определения возможности использования метода реконструкции нуклидного состава для определения НФХ активной зоны реактора ИРТ-Т предлагается проведение бенчмаркинга, состоящего из двух этапов:

– сопоставление пространственных распределений энерговыделения, полученных с использованием расчетного и реконструированного нуклидного составов на основе тестовых данных;

– реконструкция реальных топливных загрузок активной зоны реактора ИРТ-Т и определение величины отклонения реактивности от равновесного состояния при эксплуатационных критических положениях РО СУЗ, а также сопоставление результатов с референтной (аттестованной) расчетной моделью;

Сопоставление пространственных распределений энерговыделения в рамках тестовых задач осуществлялось на основе ранее предложенного разбиения (рисунок 2.6), состоящего из 6-ти высотных слоев, 8-ми азимутальных слоев на один ТВЭЛ.

Чтобы получить расчетный нуклидный состав моделировался процесс работы реактора на мощности по типу «выгорание-перегрузка». По результатам серии расчетов были сформированы более 20 тестовых картограмм, которые использовались для реконструкции нуклидного состава и проведения бенчмарков. Моделирование НХФ расчетных и реконструированных компоновок осуществлялось при одних и тех же параметрах, чтобы исключить влияние погрешности расчетов на конечный результат.

В качестве критериев для определения «качества» метода реконструкции выбраны: коэффициент детерминации R^2 , среднее (СОО) и максимальное относительное отклонения (МОО), что позволит сравнить результаты моделирования и интерпретировать их в контексте масштаба.

В таблице 2.7 представлена тестовая картограмма выгорания топлива активной зоны, полученная путем моделирования и реконструкции.

Таблица 2.7 – Расчетная и реконструированная тестовая картограмма выгорания топлива активной зоны реактора ИРТ-Т

	Расчетная, %				Реконструированная, %				
	В	С	Д	Е	В	С	Д	Е	
7	19,46	57,85	59,34	9,37	19,65	58,41	59,93	9,55	
6	48,76	14,04	32,86	22,67	49,22	14,23	33,23	23,01	
5	8,27			44,09	8,43			44,69	
4	58,35			42,84	59,04			43,44	
3	47,39	29,02	13,63	21,11	47,91	29,41	13,80	21,44	
2	18,58	54,94	55,12	7,76	18,90	55,54	55,68	7,93	
СОО по ячейкам, %:		1,13							
МОО по ячейкам, %:		1,19							

МОО и СОО реконструкции картограммы выгорания не превышают 1,13 % и 1,19 %, соответственно. Сопоставление ядерных концентраций некоторых нуклидов для ячеек 7С (выгоревшая ТВС) и 2Е (относительно «свежая» ТВС) приведено на рисунке 2.18.

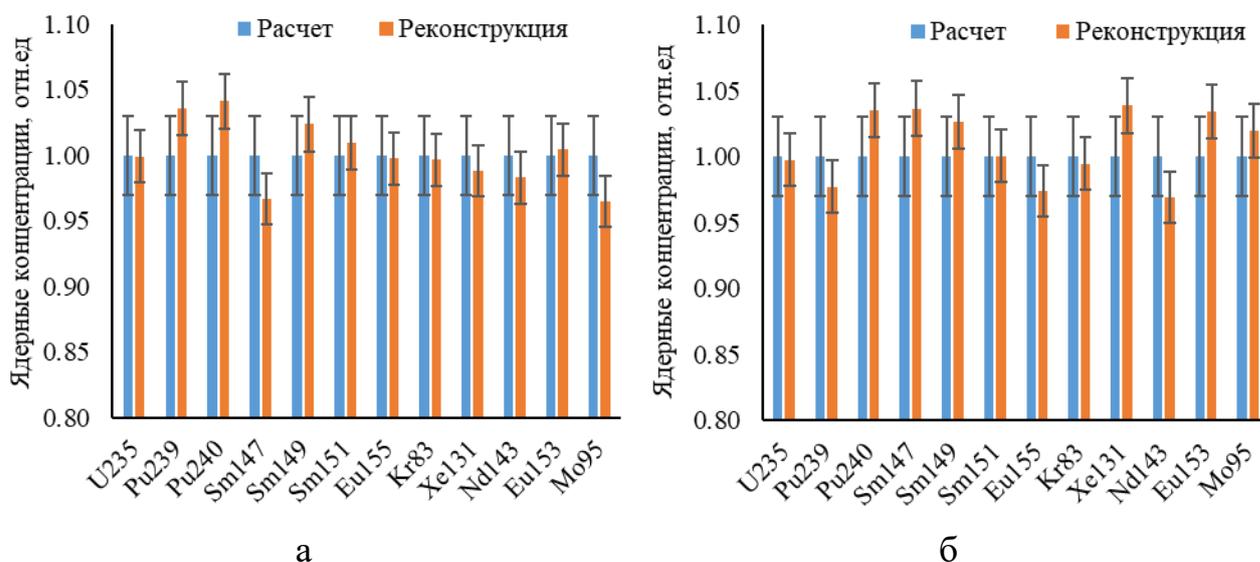


Рисунок 2.18 – Сопоставление ядерных концентраций некоторых нуклидов в топливе: а – ячейка 7С; б – ячейка 2Е

Проводилось сопоставление ядерных концентраций изотопов плутония, а также «шлаков» с наибольшими сечениями поглощения нейтронов, которые оказывают влияние на НФХ активной зоны реактора. СОО реконструкции концентраций нуклидов составила $\approx 3\%$, что обусловлено усреднением значений при формировании исходных массивов данных. Полученное значение СОО

удовлетворяет максимальной погрешности расчета нуклидного состава, установленной в аттестационном паспорте ПС MSU-PTR.

Для каждой подготовленной топливной загрузки моделировались НФХ и определялись интегральные значения энерговыделения и КНРЭ, чтобы оценить качество реконструированного нуклидного состава в каждой топливной ячейке и наиболее напряженных участках. В таблице 2.8 представлено сравнение распределений энерговыделения по ячейкам активной зоны реактора ИРТ-Т.

Таблица 2.8 – Сопоставление суммарного энерговыделения в ячейках активной зоны для расчетного и реконструированного нуклидного составов

	Расчетная, кВт				Реконструированная, кВт			
	В	С	Д	Е	В	С	Д	Е
7	290,0	216,7	226,0	373,6	289,3	212,9	218,5	373,9
6	216,1	371,3	341,7	372,6	217,1	376,5	345,0	375,4
5	363,5			357,2	369,9			353,9
4	221,1			351,3	214,7			347,1
3	214,5	304,8	367,2	350,1	214,8	309,5	374,0	354,3
2	270,6	211,8	223,5	356,4	271,4	208,9	217,0	355,9

СОО по ячейкам, %: 0,38

МОО по ячейкам, %: 0,68

Из значений, представленных в таблице 2.8 видно, что СОО определения энерговыделения в ячейках активной зоны не превышает 0,38 %. Сопоставление значений КНРЭ в ячейках тестовой картограммы представлено в таблице 2.9.

Таблица 2.9 – Сопоставление значений КНРЭ по ячейкам активной зоны для расчетного и реконструированного нуклидного составов

	Расчетная				Реконструированная			
	В	С	Д	Е	В	С	Д	Е
7	1,41	0,89	0,89	2,01	1,47	0,92	0,93	1,97
6	1,09	2,19	1,55	1,86	1,04	2,16	1,52	1,90
5	2,27			1,46	2,30			1,51
4	0,93			1,46	0,93			1,49
3	1,05	1,46	2,02	1,80	1,01	1,46	2,03	1,83
2	1,38	0,87	0,92	2,00	1,39	0,89	0,92	2,00

СОО по ячейкам, %: 2,2

МОО по ячейкам, %: 4,6

Из таблицы 2.9, следует, что среднее и максимальное отклонения определения КНРЭ между расчетным и реконструированным нуклидным составом не превышают 2,2 % и 4,6 %, соответственно. Отклонения значений суммарного энерговыделения и КНРЭ обусловлены погрешностью реконструкции ядерных концентраций.

Далее было проведено сравнение стандартизированных пространственных распределений энерговыделения по высотной и азимутальной составляющим. Для сопоставления высотных распределений рассматривались восьми- и шеститрубная ТВС, для азимутальных распределений рассматривались наиболее и наименее энергонапряженные ячейки активной зоны.

На рисунке 2.19 представлены пространственные распределения энерговыделения по высоте шеститрубной ТВС (ячейка 6В) и восьмитрубной ТВС (ячейка 5Е).

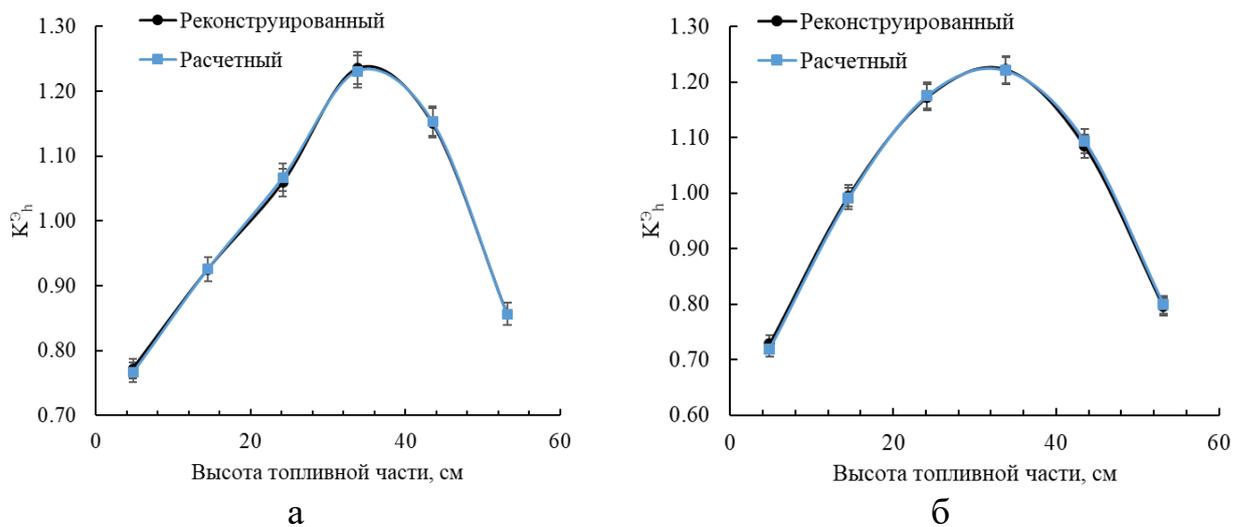


Рисунок 2.19 – Распределение энерговыделения по высоте в некоторых ячейках: а –ячейка 6В; б –ячейка 5Е

Из рисунка 2.19 видно, что распределения не имеют существенных отличий на каждом высотном участке, а сходимость составила $R^2 \approx 0,99$ для каждой ячейки.

На рисунке 2.20 представлены пространственные распределения энерговыделения в первом твэле наиболее (ячейка 5Е) и наименее (ячейка 7В) напряженных ячейках тестовой картограммы.

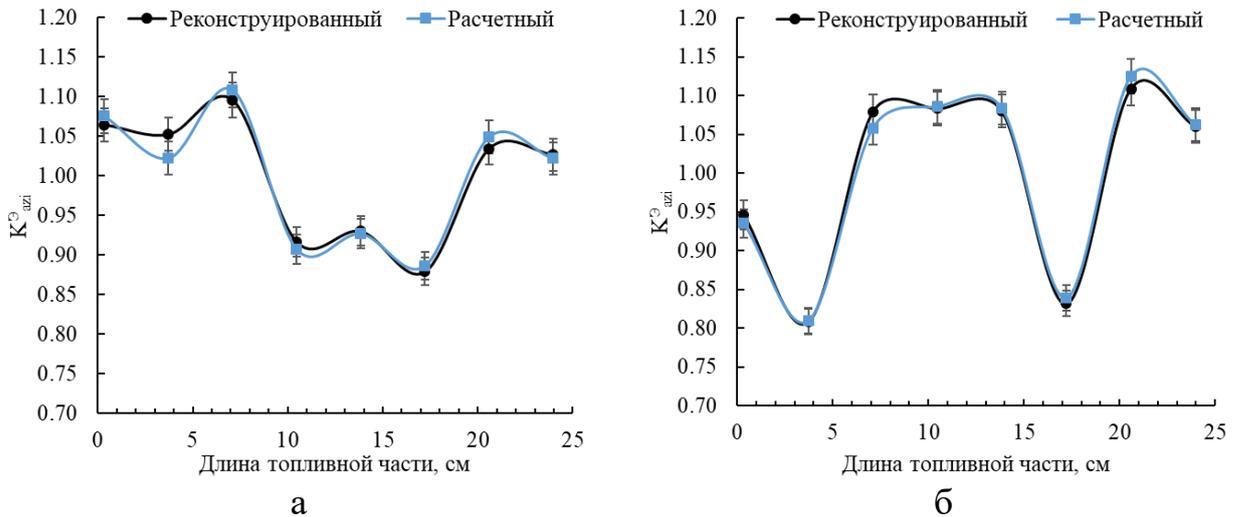


Рисунок 2.20 – Распределение энерговыделения в наименее и наиболее напряженных ячейках: а –ячейка 7В; б –ячейка 5Е

Сходимость значений по критерию R^2 составляет 0,97 и 0,99 для ячеек 7В и 5Е, соответственно. Среднее значение R^2 по всем азимутальным секторам ячеек активной зоны составляет 0,96.

По результатам сравнительного анализа тестовых компоновок с расчетным и реконструированным составом топлива необходимо отметить, что:

- СОО реконструкции глубины выгорания по топливным ячейкам не превышает 1,13 %;
- СОО реконструкции ядерных концентраций основных изотопов плутония и «шлаков» с высокими сечениями поглощения составила ≈ 3 %;
- СОО определения энерговыделения в топливных ячейках при реконструкции нуклидного состава не превышает 0,38 %;
- СОО и МОО при определении КНРЭ в активной зоне не превышают 2,2 % и 5,8 %, соответственно;
- высотные распределения энерговыделения имеют высокую степень сходимости $R^2 \approx 0,99$;
- азимутальные распределения энерговыделения имеют среднее значение сходимости по критерию $R^2 \approx 0,96$.

Таким образом, предложенная концепция о реконструкции может быть использована для восстановления нуклидного состава топлива при любом

геометрическом разбиении ТВС. Общая точность восстановленных распределений энерговыделения составила $R^2 \approx 0,95$, при СОО по ячейкам 0,38 %.

В рамках следующего этапа тестирования был осуществлен переход к геометрии референтной расчетной модели и проведена реконструкция некоторых топливных загрузок активной зоны за период эксплуатации реактора 2021-2023 гг. Качество реконструкции относительно эксплуатационных характеристик реактора и допустимых пределов погрешности оценивалось на основе среднего абсолютного отклонения (САО).

Для выбранных компоновок моделировались НФХ как с учетом РО (экспериментальные положения), так и без (РО взведены). Оценивалось отклонение от критического состояния и запас реактивности активной зоны относительно аттестованной модели и экспериментальных данных реактора ИРТ-Т (рисунок 2.21).

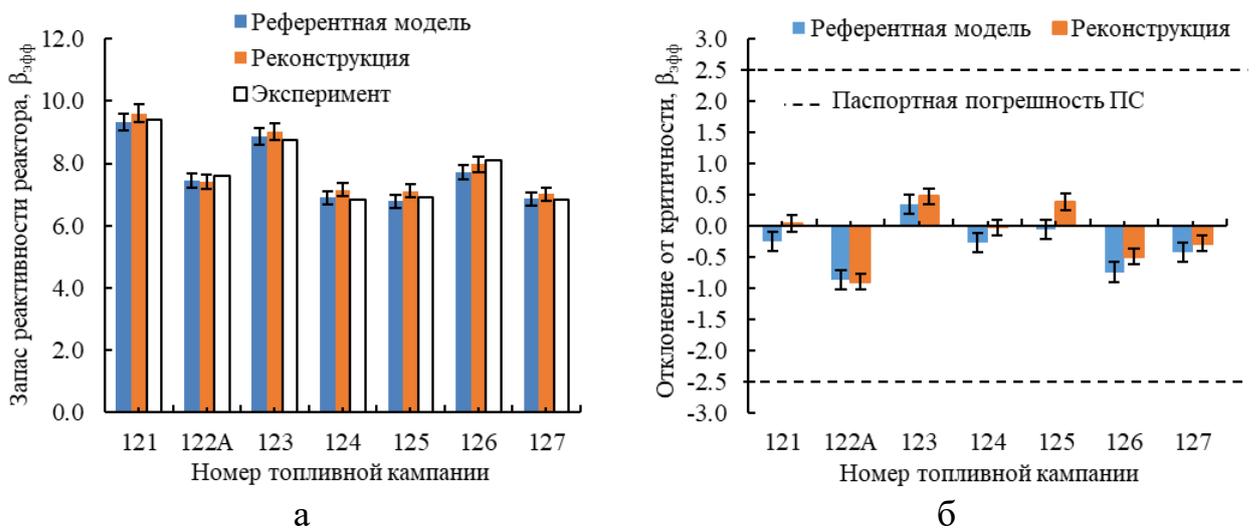


Рисунок 2.21 – Сопоставление метода реконструкции с референтной моделью и экспериментальными данными реактора ИРТ-Т: а – определение запаса реактивности; б – отклонение от экспериментальной критичности реактора

Из рисунка 2.21 видно, что результаты реконструкции согласуются с референтной моделью. САО реконструкции от экспериментальных данных при определении запаса реактивности составило $0,31 \beta_{эфф}$. САО реконструкции от экспериментальной критичности составило $0,38 \beta_{эфф}$. Погрешности определения

эксплуатационных характеристик активной зоны реактора ИРТ-Т при помощи метода реконструкции не превышают максимальную погрешность ПС $\pm 2,5 \beta_{эфф}$.

Для подтверждения стабильности расчетной модели с реконструированным составом топлива при динамических расчетах (выгорание) проводилось моделирование эксплуатационных циклов, учитывающее работу на мощности и плановые остановки. Полученные результаты сопоставлялись с референтной моделью и экспериментальными данными (рисунок 2.22).



Рисунок 2.22 – Оценка стабильности модели с реконструированным составом топлива при моделировании рабочих циклов

Можно видеть, что реконструированный нуклидный состав корректно описывает НФХ активной зоны, учитывая изменение концентраций ядер ксенона-135 при эксплуатационных циклах. САО относительно экспериментальных значений составило $0,28 \beta_{эфф}$, что не превышает допустимую погрешность.

Результаты проведенных бенчмарков показывают, что предложенная концепция реконструкции нуклидного состава позволяет восстанавливать реальные топливные загрузки активной зоны реактора ИРТ-Т и оценивать пространственные распределения энерговыделения при любом геометрическом разбиении ТВС, а также может быть использована для определения характеристик активной зоны в рамках эксплуатационных циклов.

Более того, создание новых (искусственных) топливных компоновок может быть использовано для исследований НФХ и закономерностей формирования энерговыделения в активной зоне реактора ИРТ-Т.

2.6 Результаты и выводы по главе 2

По результатам исследований, проведенным в настоящей главе, можно сделать следующие выводы:

– эксплуатация реактора ИРТ-Т в режиме частичных перегрузок является причиной формирования локальных энергонапряженных участков и перераспределения энерговыделения по активной зоне. Использование типового регламента перегрузок / перестановок и детерминированный поиск оптимальной топливной загрузки не представляются возможным, что обусловлено отсутствием симметричных топливных ячеек в активной зоны и большим разнообразием возможных комбинаций ТВС. Индивидуальные программы перестановочных работ разрабатываются на основе серий длительных расчетов в модели без азимутального разбиения, что не позволяет судить об эффективности профилирования (сформированной загрузки) и корректно оценивать предельно напряженные участки в активной зоне;

– предложен новый подход на основе суррогатного моделирования, включающий в себя использование ПС MCU-PTR для формирования массивов данных и описания физических процессов в активной зоне реактора, прогнозные ИИ-модели и алгоритм адаптивного интеллектуального поиска. Подход позволит предсказывать реактивностные характеристики, распределение энерговыделения в топливных элементах и формировать оптимальные картограммы загрузок активной зоны реактора ИРТ-Т;

– предложен новый подход к восстановлению топливных загрузок активной зоны реактора, который позволяет избежать традиционных ресурсозатратных расчетов, базирующихся на моделировании истории эксплуатации реактора (1984г. - н.в.). Подход основан на математической

реконструкции нуклидного состава топлива с учетом неравномерности распределения выгорания в гетерогенной структуре топливных элементов;

– для реализации метода формировались массивы данных, описывающие неравномерность распределения выгорания по высотной, поперечной и азимутальной координатам, на основе которых были установлены пространственные функциональные зависимости $\mathbf{K}^B = f(B)$. Сформированы массивы $\mathbf{N} = f(\mathbf{B})$, характеризующие выход более 140 радиоактивных и стабильных нуклидов, что позволяет восстанавливать ядерные концентрации в топливе исходя из глубины выгорания U-235;

– проведена верификация подхода на основе сопоставления с тестовыми (модельными) расчетами в ПС MCU-PTR. Погрешность реконструкции выгорания топлива по всей активной зоне составила не более 1,19 %, при средней погрешности ядерных концентраций нуклидов ≈ 3 %. Оцененная погрешность определения суммарного энерговыделения в ячейках составила не более 0,68 %, при погрешности определения КНРЭ в ячейках не более 4,6 %. Сходимость пространственных распределений энерговыделения по высотной и азимутальной координатам для тестовых картограмм составила 0,99 и 0,95 по критерию R^2 , соответственно. Высокая сходимость результатов свидетельствует о возможности применения предложенного метода математической реконструкции для оценки распределения энерговыделения при любой топливной загрузке активной зоны реактора ИРТ-Т;

– проведена валидация метода на основе сопоставления с результатами аттестованной модели и эксплуатационных данных реактора ИРТ-Т за 2021-2023 гг. По результатам сопоставления установлено, что САО реконструкции от экспериментальных значений составило $0,31 \beta_{эфф}$ и $0,38 \beta_{эфф}$ для параметров запаса реактивности и экспериментальной критичности, соответственно, что согласуется с результатами аттестованной модели и не превышает максимальную погрешность ПС $\pm 2,5 \beta_{эфф}$.

Глава 3. Прогнозное определение эксплуатационных характеристик активной зоны реактора ИРТ-Т

3.1 Статистический анализ распределений энергонапряженности и запаса реактивности

Из результатов исследований, представленных в разделах 2.4, 2.5 видно, что характер распределений в ТВЭлах имеет многомерный и нелинейный профиль, который зависит как от глубины выгорания топлива, так от ячейки активной зоны (центр, периферия). Несмотря на то, что предложенный подход к реконструкции позволяет «воссоздавать» пространственный профиль выгорания с нуклидным составом, для определения значений КНРЭ и размножающих свойств активной зоны требуется моделирование процесса переноса излучения.

Для описания распределения и изменения энерговыделения в гетерогенной структуре активных зон и реактивностных характеристик определяются функционалы [97]:

$$\begin{aligned}
 P &= \int_{dV} dr \int_{d\Omega} dE \varphi(r, \Omega, E) \Phi(r, \Omega, E), \\
 k_{eff} &= \int_{dV} dr \int_{d\Omega} dE \nu \Sigma_f(r, \Omega, E) \Phi(r, \Omega, E),
 \end{aligned}
 \tag{3.1}$$

где,

$dr d\Omega dE$ – область интегрирования в фазовом пространстве, где координаты нейтрона определяются радиус-вектором r , направлением скорости Ω и энергией E ;

$\varphi(r, \Omega, E)$ – весовая функция, определяющая вид функционала;

$\Phi(r, \Omega, E)$ – функция пространственно-энергетического распределения нейтронов;

ν – выход нейтронов;

$\Sigma_f(r, \Omega, E)$, – функция макроскопического сечения ядерной реакции деления;

Искомая функция пространственного распределения учитывает факторы гетерогенности среды: отражатель, поглощающие элементы и соседние ТВС. При этом относительно всей активной в независимости от конфигурации топлива выполняется условие:

$$P_c = \int \int_V \Sigma_f(r) \Phi(r) dV = const \quad (3.2)$$

где,

V – объем активной зоны.

Подбор аппроксимирующей функции в явном виде, корректно описывающей пространственно-энергетические зависимости с учетом различных комбинаций ТВС, представляет собой сложную задачу. Поэтому для подобных задач наибольшее распространение получила не прямая математическая формализация, а обобщение зависимостей (связей) в данных на основе инструментов машинного обучения.

Перераспределение энерговыделения по ячейкам активной зоны реактора ИРТ-Т в общем случае может быть описано согласно (3.3).

$$\begin{aligned} K_{\mathcal{Z}} \sim P &= P^{aver} \cdot f(\mathbf{B}) \cdot f(C_{PO}, C_{cell}, C_{FAs}), \\ K_{\mathcal{Z}}^i &\neq K_{\mathcal{Z}}^j, \end{aligned} \quad (3.3)$$

где,

P^{aver} – средняя мощность в ячейке;

i, j – индексы ячеек активной зоны;

$f(\mathbf{B})$ – функция, характеризующая влияние выгорания топлива на энергонапряженность ТВС;

$f(C_{PO}, C_{cell}, C_{FAs})$ – поправочная функция, характеризующая влияние РО СУЗ, соседних ТВС и расположение ячейки на энергонапряженность.

Для полностью «равномерной» активной зоне факторы гетерогенности отсутствуют, то есть $f(\lambda, C_{PO}, C_{cell}, C_{FAs}) = 1$ – энерговыделение в каждой точке пространства соответствует среднему значению. Поправочная функция учитывает компоненты, описывающие гетерогенность и флуктуации за счет множества комбинаций ТВС, поэтому ее выражение в явном виде затруднительно и требует детального рассмотрения.

Запас реактивности активной зоны, в отличие от энергонапряженности ячеек, представляет собой макропараметр системы. Для описания особенностей формирования значений запаса реактивности предлагается запись:

$$\rho = f(\mathbf{B}_{\text{core}}) \cdot f(\mathbf{C}_{\text{PO}}, \mathbf{C}_{\text{FAs}}), \quad (3.4)$$

где,

$f(\mathbf{B}_{\text{core}})$ – функция, характеризующая влияние выгорания активной зоны на запас реактивности;

$f(\mathbf{C}_{\text{PO}}, \mathbf{C}_{\text{FAs}})$ – поправочная функция, характеризующая влияние РО СУЗ и соседних ТВС на запас реактивности реактора.

Предлагается комбинирование методов реконструкции нуклидного состава и ИИ для предсказания значений КНРЭ в ячейках и запаса реактивности активной зоны исходя из картограммы выгорания топлива и положений РО СУЗ. В общем виде задача аппроксимации описывается согласно (3.5) и представляет реализацию суррогатного моделирования [98].

$$\begin{aligned} \hat{\mathbf{K}}_{\text{Э}} \approx \mathbf{K}_{\text{Э}} &= \hat{f}(\mathbf{B}, \mathbf{C}_{\text{PO}}, \mathbf{C}_{\text{cell}}, \mathbf{C}_{\text{FAs}}, \boldsymbol{\theta}_{\text{K}}) \approx f(\mathbf{B}, \mathbf{C}_{\text{PO}}, \mathbf{C}_{\text{cell}}, \mathbf{C}_{\text{FAs}}), \\ \hat{\rho} \approx \rho &= \hat{f}(\mathbf{B}_{\text{core}}, \mathbf{C}_{\text{PO}}, \mathbf{C}_{\text{FAs}}, \boldsymbol{\theta}_{\rho}) \approx f(\mathbf{B}_{\text{core}}, \mathbf{C}_{\text{PO}}, \mathbf{C}_{\text{FAs}}), \end{aligned} \quad (3.5)$$

где,

$\hat{\mathbf{K}}_{\text{Э}}, \mathbf{K}_{\text{Э}}$ – вектора прогнозных и истинных значения КНРЭ в ячейках, соответственно;

$\hat{\rho}, \rho$ – вектора прогнозных и истинных значения запаса реактивности, соответственно;

$\boldsymbol{\theta}_{\text{K}}, \boldsymbol{\theta}_{\rho}$ – параметры моделей для прогнозирования значений КНРЭ и запаса реактивности.

Несмотря на широкий спектр возможностей методов ИИ, они зачастую представляют собой «черный ящик» и не позволяют интерпретировать связи между входными и выходными данными. Это осложняет процесс решения задач, верификации и валидации результатов модели, а также ее внедрение в производственный цикл.

Предлагается провести статистическое исследование [99–101] относительно многомерных массивов данных, описывающих состояние активной зоны в зависимости от топливной конфигурации и положений РО, которое позволит получить статистические распределения энерговыделения и запаса реактивности

реактора и сформировать обобщенные закономерности на основе полуэмпирических зависимостей. Это позволит сформировать оптимальную стратегию обучения и конфигурирования моделей, а также провести их верификацию и валидацию для подтверждения интерпретируемости и физической «осмысленности».

Использование детализированной геометрии (рисунок 2.6) играет важную роль в определении наиболее напряженных участков в топливе, а перераспределение энерговыделения между ячейками в результате изменения конфигурации топлива хорошо описывается упрощенной геометрией (без азимутального разбиения ТВЭЛов). Связь между упрощенной и детальной геометрией для одной и той же топливной загрузки может представлена исходя из (2.2) и (2.5):

$$\frac{K_V^D}{K_V^Y} = \frac{K_h^D K_c^D K_{fe}^D K_{azi}^D}{K_h^Y K_c^Y} = K_{fe}^D K_{azi}^D, \quad (3.6)$$

где,

D, Y – индексы детальной и упрощенной геометрии ТВС, соответственно.

При формировании прогнозных моделей целесообразно начать установление обобщенных закономерностей с упрощенной геометрии, которая учитывает коэффициенты неравномерности по ячейкам и высоте. В последствие сформированные зависимости могут быть использованы для установления аналогичных связей в детальной геометрии относительно азимутальных секторов, что позволит эффективно решить сформулированную задачу (3.5) и определять как эффекты перераспределения энерговыделения, так и «всплески» КНРЭ (плотности энерговыделения) в наиболее напряженных секторах.

3.1.1 Статистические распределения значений энерговыделения и запаса реактивности

Ранее было показано, что при изменении топливной компоновки происходит перераспределение энерговыделения по всей активной зоне.

Следовательно, важными элементами достоверного обобщения зависимостей являются количество и качество исходных данных.

Использование реальных топливных загрузок за период эксплуатации реактора 1984-2024 гг. не представляется возможным:

- недостаточно примеров для качественного описания зависимостей в ячейках (рисунок 3.1) – искаженные профили плотности распределения вероятности по сравнению с теоретической кривой;

- продолжительный период эксплуатации, за который были заменены элементы активной зоны: отражатель, центральные экспериментальные каналы, что оказывает влияние на НФХ.

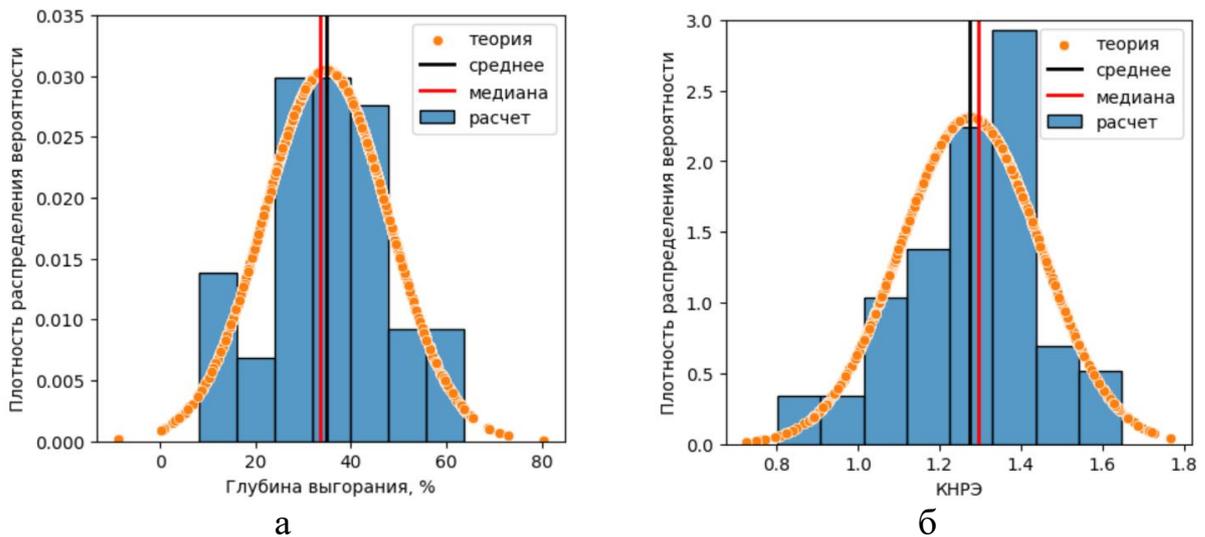


Рисунок 3.1 – Распределения значений в топливной ячейке, полученные на основе эксплуатационных (реальных) загрузок:

а – глубина выгорания; б – КНРЭ

Чтобы установить обобщенные закономерности распределения энерговыделение в зависимости от комбинаций ТВС и положений РО СУЗ требуется датасет, содержащий разнообразные компоновки. «Традиционное» формирование исходных данных топливных загрузок по принципу «выгорание-перегрузка» потребует моделирования большого количества циклов, чтобы достичь достаточного разнообразия значений глубины выгорания в каждой ячейке. Поэтому предлагается альтернативный подход, основанный на генерации случайных (искусственных) топливных загрузок с реконструированным

нуклидным составом топлива, последующим моделированием этих состояний в ПС MCU-PTR и программной обработкой результатов (рисунок 3.2).

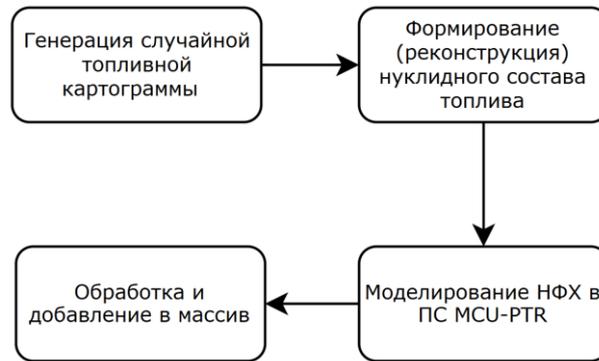


Рисунок 3.2 – Схема формирования топливных загрузок

С целью подробного описания НФХ, соответствующих реальному состоянию активной зоны, в процессе формирования топливных загрузок учитывались эксплуатационные особенности:

- рассматривается фиксированная загрузка, содержащая 11 восьмитрубных и 9 шеститрубных ТВС;
- частично учитывается влияние концентраций «отравителей» (Li^6 , He^3) в бериллиевом отражателе на размножающие свойства активной зоны (рисунок 3.3). Нуклидный состав в каждом блоке отражателя усреднен с учетом эксплуатационных циклов работы реактора за период 2021–2023 гг;
- учитывается регламентное перемещение групп РО СУЗ в активной зоне;
- значения глубины выгорания в каждой ячейке – случайные независимые величины;
- генерируемая случайным образом картограмма представляет собой выборку, обладающую основными свойствами популяции.

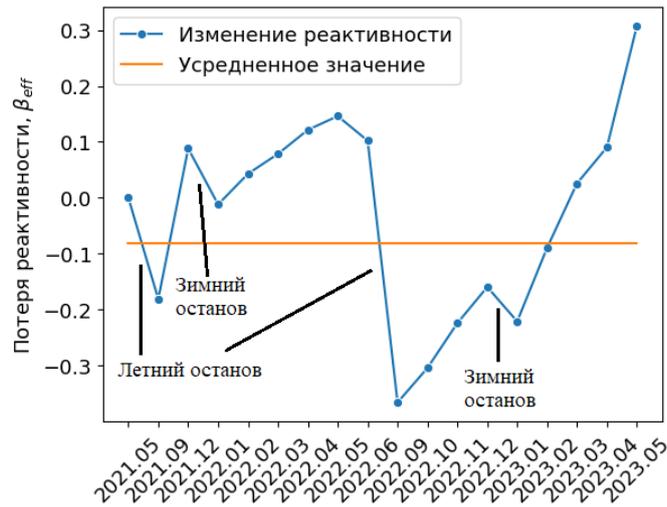


Рисунок 3.3 – Влияние изменения ядерных концентраций «отравителей» в бериллии на размножающие свойства активной зоны реактора ИРТ-Т

Для того, чтобы случайно генерируемые топливные загрузки описывали характеристики реальных картограмм, рассматривался массив значений глубины выгорания $\mathbf{V}_{\text{core}} = [B_1, \dots, B_C]$, соответствующий эксплуатационным данным (рисунок 3.1) и который может быть описан нормальным законом $\mathbf{V}_{\text{core}} \sim N(\theta_1, \theta_2)$ с функцией плотности вероятности (3.7). Используя метод максимального правдоподобия можно определить параметры модели, при которых функция (3.8) максимальна, а (3.9) описывает распределение значений \mathbf{V}_{core} .

$$N_{\mathbf{V}}(B_i; \theta_1, \theta_2) = \frac{1}{\sqrt{2\pi\theta_2^2}} \exp\left[-\frac{(B_i - \theta_1)^2}{2\theta_2^2}\right], \quad (3.7)$$

$$\ln N_{\mathbf{V}}(B_i; \theta_1, \theta_2) = -\sum_{i=1}^n \frac{(x_i - \theta_1)^2}{2\theta_2^2} + \sum_{i=1}^n \frac{1}{\sqrt{2\pi\theta_2^2}}, \quad (3.8)$$

$$N_{\mathbf{V}}(B_i; \sigma_e, \mu_e) = \frac{1}{\sqrt{2\pi\sigma_e^2}} \exp\left[-\frac{(B_i - \mu_e)^2}{2\sigma_e^2}\right], \quad (3.9)$$

где,

θ_1, θ_2 – неизвестные параметры модели (среднее значение и стандартное отклонение);

σ_e – оцененное стандартное отклонение;

μ_e – оцененное среднее значение.

Оцененные среднее и стандартное отклонение составили 34,5 % и 11,5 % в единицах глубины выгорания, соответственно. По эмпирическому правилу «68–95–99,7» предельные значения глубины выгорания в активной зоне при 3σ равны 0% и 69 %, что соответствует реальным значениям «свежей» и выгоревшей ТВС. Таким образом, при искусственной генерации создаются топливные загрузки, содержащие случайные значения выгорания в ячейках (набор ТВС), которые описывают состояние активной зоны в разные моменты топливной кампании.

На основе гауссовской модели были получены более $n = 250$ уникальных вариантов топливных загрузок, для каждой из которых рассматривались 11 положений РО СУЗ, описывающих регламентное перемещение в процессе кампаний. При выводе реактора ИРТ-Т в критическое состояние (или при повышении мощности) сначала осуществляется извлечение группы КОЗ, после чего совместное извлечение групп КО1 и КО2. Для сформированных загрузок были рассмотрены:

- 3 положения группы КОЗ: 15 см, 7,5 см и 0 см при полностью погруженных группах КО1 и КО2;
- 8 положений групп КО1 и КО2: от 60 см до 0 см с шагом 7,5 см при полностью извлечённой группе КОЗ;

Всего были сформированы и определены НФХ для более чем 2750 состояний активной зоны реактора ИРТ-Т. После программной обработки результатов были подготовлены массивы данных, содержащие положения стержней регулирования, значения глубины выгорания, КНРЭ в ячейках и запаса реактивности активной зоны. Это позволит определить особенности формирования энерговыделения и размножающих свойств активной зоны в зависимости от комбинаций ТВС с разной глубиной выгорания и положений РО.

С целью общей оценки распределений в данных и корректности модели, на основе подходов описательной статистики проводился анализ подготовленного массива. На рисунке 3.4 представлена плотность распределения глубины выгорания в некоторых топливных ячейках.

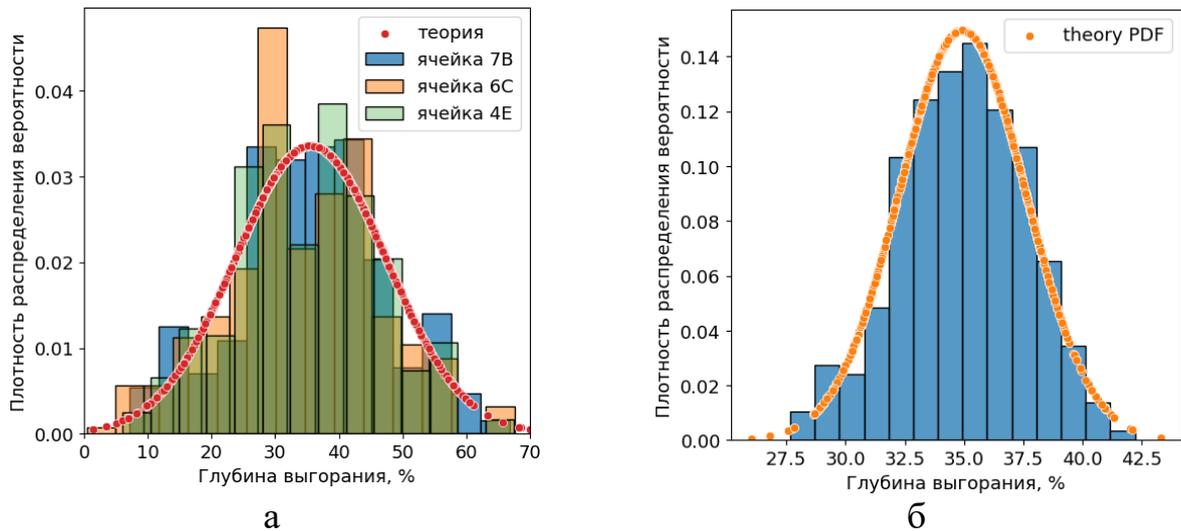


Рисунок 3.4 – Распределения значений глубины выгорания: а – некоторые ячейки активной зоны; б – среднее по топливным загрузкам (выборке)

Из рисунков можно видеть, что значения глубины выгорания в ячейках изменяются от 0 % до 70 %, что позволяет судить о равномерном распределении значений при использовании гауссовской модели. Среднее значение глубины выгорания по активной зоне варьируется от 27 % до 42 %, что соответствует реальным экспериментальным данным реактора (рисунок 3.1а).

Сравнительный анализ значений КНРЭ осуществлялся в два этапа: оценка распределений при фиксированном положении РО с целью определения энергонапряженности в ячейках в зависимости от глубины выгорания; определение процессов локального увеличения и уменьшения энерговыделения в результате влияния поглощающих стержней.

Распределения значений КНРЭ для некоторых ячеек активной зоны при фиксированном положении стержней (все РО взведены) представлены на рисунке 3.5.

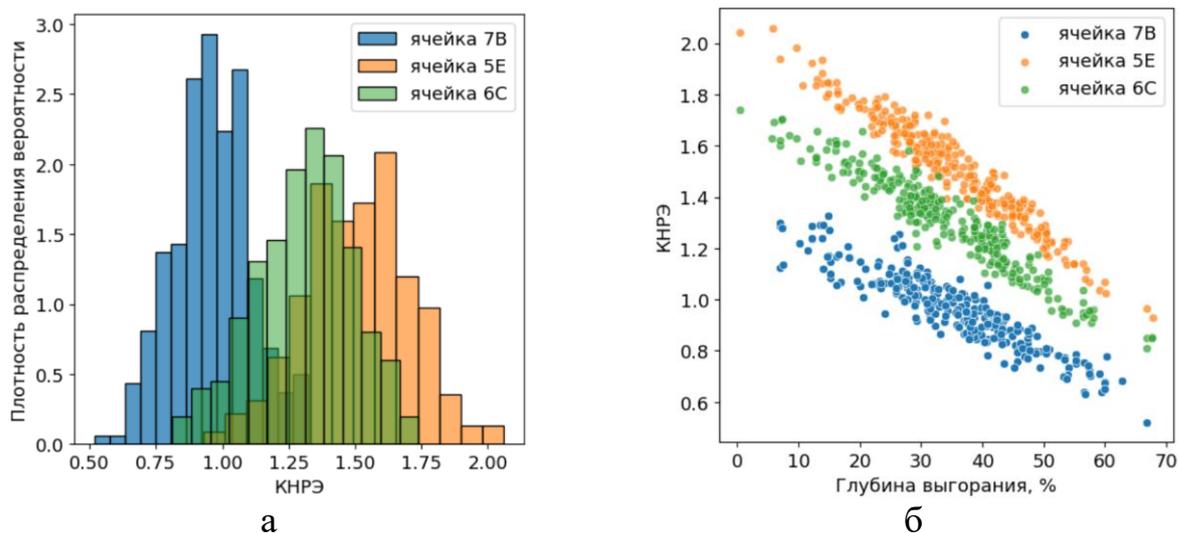


Рисунок 3.5 – Распределение значений КНРЭ в некоторых ячейках при взведенных РО: а – гистограммный вид; б – зависимость КНРЭ от глубины выгорания

Среднее значение КНРЭ между периферийной и центральной ячейкой отличается в ≈ 2 раза. Несмотря на небольшой размер выборки между распределениями присутствуют существенные различия, что свидетельствует о степени энергонапряженности ячеек (периферия, центр) и наличии разной силы связи в данных.

Изменение степени энергонапряженности ячеек в результате влияния РО СУЗ представлено на рисунке 3.6.

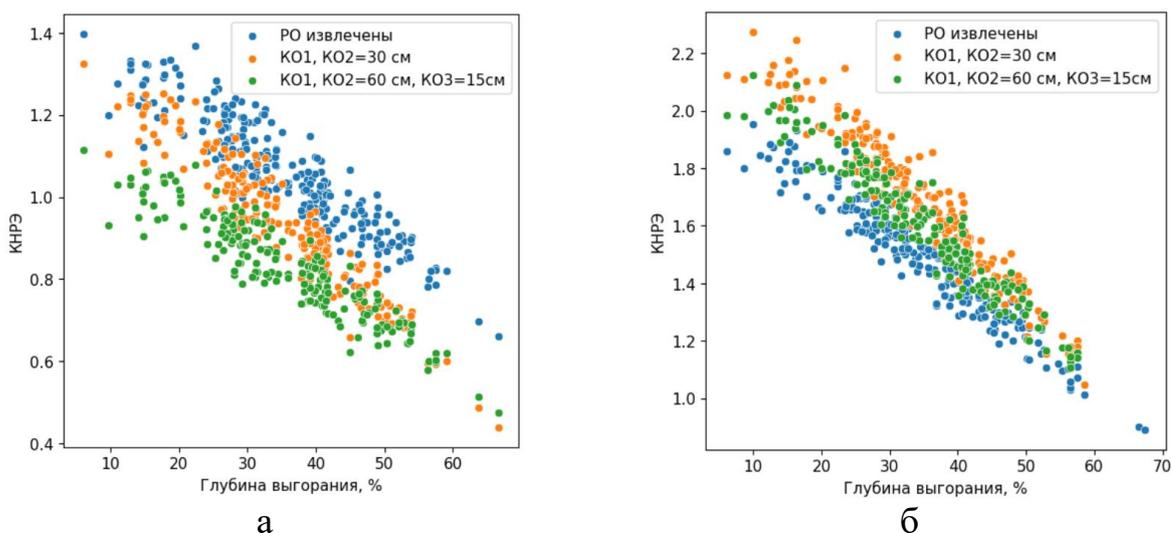


Рисунок 3.6 – Распределение значений КНРЭ при разных положения РО: а – ячейка 6Е (шеститрубная ТВС с РО); б – ячейка 5Е

Как можно видеть из распределений рисунка 3.6, при погружении РО (КО1, КО2 = 60 см, КО3 = 15 см) наблюдается снижение энергонапряженности ТВС в ячейке 6Е в среднем на 21 %, которое сопровождается ростом энерговыделения в других ячейках. Так, наибольший рост теплонапряженности ячейки 5Е $\approx 9,5$ % наблюдается при положениях групп КО1, КО2 равных 30 см, что позволяет судить об эффектах локального «искажения» и «выдавливания» поля нейтронов.

Изменение запаса реактивности при различных положения РО СУЗ и семейство кривых, характеризующих эффективность поглощающих стержней в зависимости от положения и степени выгорания топлива, приведены на рисунке 3.7.

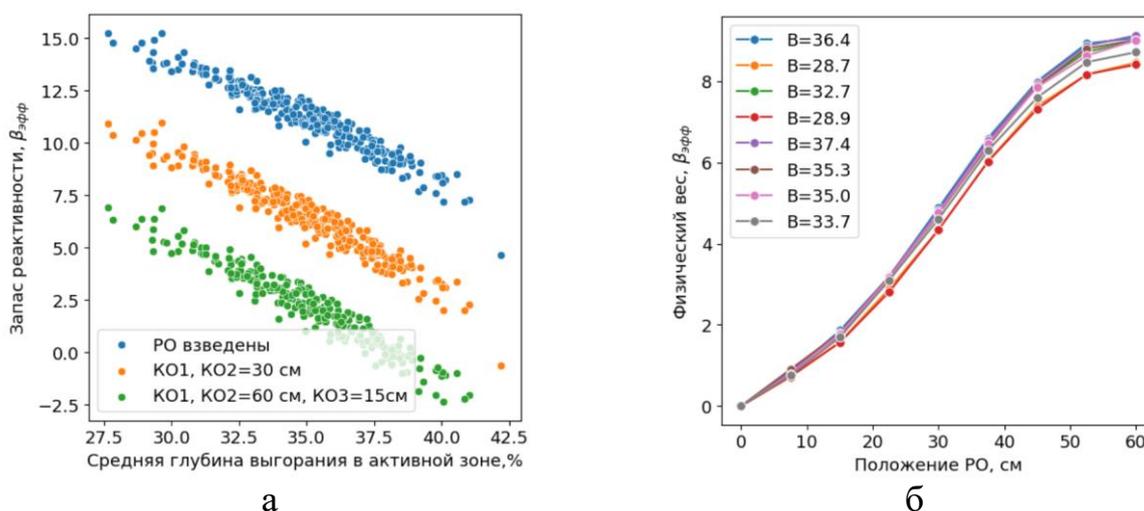


Рисунок 3.7 – Изменение запаса реактивности реактора:

а – распределения значений при некоторых положениях РО;

б – семейство кривых, характеризующих эффективность РО КО1, КО2

Из зависимостей рисунка 3.7 следует, что в зависимости от положений РО происходит изменение величины запаса реактивности, но общий характер распределений фиксирован, а наблюдаемые флуктуации обусловлены множеством комбинаций ТВС. При этом на количественную эффективность РО влияют как глубина выгорания, так и комбинации ТВС.

Для определения вылетов или искажений в массивах рассчитывались показатели описательной статистики, среди которых: среднее, медиана med , коэффициенты асимметрии As и эксцесса Es для определения эффектов

«скошенности» и оценки поведения данных в «хвостах» распределений. В таблице 3.1 приведены показатели описательной статистики для всех ячеек активной зоны при наибольшей энергонапряженности в ячейках (положения групп КО1, КО2 равны 30 см).

Таблица 3.1 – Показатели описательной статистики для топливных ячеек активной зоны при положениях КО1, КО2 равных 30 см

№	Глубина выгорания топлива, %				КНРЭ			
	\bar{X}	<i>med</i>	<i>As</i>	<i>Es</i>	\bar{X}	<i>med</i>	<i>As</i>	<i>Es</i>
7B	35,53	36,13	-0,08	-0,16	1,13	1,12	0,09	0,04
7C	35,17	34,92	0,15	-0,36	1,27	1,28	-0,27	-0,40
7D	34,71	34,30	0,26	-0,19	1,38	1,39	-0,06	-0,28
7E	34,09	33,22	0,03	-0,28	1,39	1,39	-0,03	-0,14
6B	35,60	35,14	-0,28	0,15	1,14	1,14	-0,28	0,19
6C	34,15	33,80	0,03	0,05	1,44	1,46	-0,33	-0,11
6D	33,85	33,78	0,09	-0,28	1,55	1,58	-0,44	-0,20
6E	35,71	35,12	-0,13	-0,36	1,44	1,45	-0,11	-0,34
5B	35,49	35,84	-0,01	-0,30	1,33	1,34	-0,19	-0,13
5E	35,31	34,46	-0,08	-0,08	1,73	1,73	-0,04	0,12
4B	35,33	35,77	-0,08	-0,21	1,32	1,33	-0,18	-0,03
4E	34,99	34,92	0,02	-0,24	1,68	1,70	-0,12	-0,21
3B	35,62	34,21	-0,01	-0,37	1,10	1,10	-0,07	-0,33
3C	34,33	32,45	-0,01	-0,48	1,35	1,36	-0,09	-0,34
3D	35,75	34,86	0,01	-0,33	1,40	1,41	-0,19	-0,07
3E	33,85	34,43	-0,17	-0,39	1,35	1,36	-0,05	-0,33
2B	35,03	35,77	-0,23	-0,22	1,09	1,09	-0,05	0,01
2C	33,26	34,02	-0,01	-0,30	1,22	1,21	0,16	-0,17
2D	35,38	35,33	-0,03	-0,07	1,23	1,22	0,16	0,41
2E	35,57	35,53	-0,07	0,03	1,25	1,26	0,04	0,34

Исходя из показателей таблицы 3.1, можно заключить, что присутствуют зависимости между ячейкой, глубиной выгорания и величиной КНРЭ. Так, при одной и той же глубине выгорания в периферийной и центральной ячейках энерговыделение отличаются более чем 1,5 раз (1,73 и 1,13 в ячейках 5E и 7B, соответственно), но в некоторых случаях, когда рассматриваются «свежая» и выгоравшая ТВС, плотность энерговыделения может отличаться более чем в 3 раза.

Для большей части топливных ячеек характерны незначительная асимметрия $|As| \in [0;0,5]$ и слабые формы лептокуртического ($Es > 0$) и

платикуртического ($Es < 0$) распределений, что обусловлено флуктуациями ввиду случайной комбинации ТВС в ячейках и размером выборки.

Рассмотрим полученные значения относительно центральной предельной теоремы (ЦПТ). ЦПТ гласит, что сумма достаточно большого количества слабо зависимых случайных величин имеет распределение, близкое к нормальному. Условие классической ЦПТ имеет вид:

$$\begin{aligned} \bar{X}_n &\rightarrow N(\mu_e, \sigma_e), \\ \bar{X}_n - \mu_e &\rightarrow 0, \text{ при } n \rightarrow \infty, \end{aligned} \quad (3.10)$$

Отклонение выборочного среднего от оцененного среднего (3.9) относительно всех топливных ячеек составило не более 3 %, что обуславливает визуальное сходство распределений с теоретической кривой (рисунок 3.4). Для подтверждения схождения предлагается количественная оценка на основе статистических тестов и инструментов оценочной статистики (размер эффекта и др.) [102].

В рамках статистического тестирования рассматривается нулевая гипотеза H_0 о наличии или отсутствии некоторого события, а в качестве количественной меры используется Р-значение. В зависимости от величины Р-значения для заданного уровня значимости α делаются выводы о принятии или опровержении H_0 . Использование статистических тестов не всегда является достаточным, так как результат теста может ошибочно свидетельствовать о важности тривиальных отличий, что обусловлено высокой чувствительностью.

Для проверки распределений в ячейках были выбраны тесты нормальности Шапиро-Уилка, который измеряет соответствие параметров выборки ожидаемым средним значениям, дисперсиям и ковариациям, и Харке-Бера, основанный на значениях асимметрии и эксцесса выборки. Уровень значимости, принятый в тестах равен $\alpha = 0,05$ [103; 104].

В качестве меры оценочной статистики использовался «размер эффекта» по коэффициенту Коэна (3.11), который показывает степень отличия одного распределения от другого [105; 106]

$$d = \frac{\mu_1 - \mu_2}{\sigma_{12}} = \frac{m_1 - m_2}{\sqrt{\frac{(n_1 - 1)\sigma_1^2 + (n_2 - 1)\sigma_2^2}{n_1 + n_2 - 2}}}, \quad (3.11)$$

где,

μ_1, μ_2 – средние значения распределений;

n_1, n_2 – размеры выборок;

σ_{12} – стандартное отклонение генеральной совокупности.

Тесты проводились для каждой топливной ячейки и показали идентичные результаты, при которых Р-значение $> \alpha$, то есть H_0 не может быть отвергнута, так как отсутствуют доказательства, что распределения «ненормальны». Р-значения по критериям Шапиро-Уилка и Харке-Бера для состояния активной зоны при РО КО1, КО2 = 30 см приведены в таблице 3.2.

Таблица 3.2 – Р-значения по критериям Шапиро-Уилка и Харке-Бера для состояния активной зоны РО КО1, КО2 = 30 см

	Шапиро-Уилка				Харке-Бера			
	В	С	D	Е	В	С	D	Е
7	0,22	0,46	0,16	0,51	0,98	0,12	0,32	0,73
6	0,07	0,18	0,26	0,11	0,20	0,09	0,08	0,29
5	0,51			0,19	0,16			0,46
4	0,20			0,12	0,40			0,35
3	0,15	0,06	0,15	0,21	0,51	0,55	0,56	0,41
2	0,10	0,09	0,72	0,28	0,61	0,45	0,49	0,69

Тесты проводились для всех состояний активной зоны, относительно входных и выходных признаков. «Выдавливание» поля нейтронного излучения в результате влияния поглощающих стержней не приводит к искажению статистических распределений.

При оценке коэффициентов Коэна распределения по ячейкам сравнивались с теоретической гауссовской выборкой. Среднее и максимальное значения d составили 0,02 и 0,11, соответственно, что ниже порогового значения ($d < 0,2$). Малое значение коэффициента Коэна и незначительное отличие средних значений по ЦПТ свидетельствуют об отсутствии разницы между распределениями. Параметрические и непараметрические методы показали, что данные распределены «нормально» в каждой топливной ячейке.

Таким образом, распределения данных не обладают признаками существенного «искажения», выбросы отсутствуют даже при небольшом размере выборки, что позволяет можно судить о возможности использования гауссовской математической модели для генерации топливных загрузок и описания процессов формирования и перераспределения энерговыделения в зависимости от глубины выгорания топлива и положения РО СУЗ в активной зоне (рисунки 3.5–3.6).

3.1.2 Определение корреляционных связей

Наличие взаимосвязей между ячейками и характер перераспределения энерговыделения можно определить исходя из корреляционного анализа. В зависимости от силы связи и количества ячеек можно судить о том, какие признаки необходимо использовать для обучения, а какие могут вызывать ложные корреляции или шумы. В качестве статистической меры предлагается использовать ранговую корреляцию Кендалла [107]:

$$r = 1 - \frac{4}{n(n-1)}(S - R) = 1 - \frac{4}{n(n-1)} \sum_{i < j}^{n=i} \text{sign}(a_j - a_i) \text{sign}(b_j - b_i), \quad (3.12)$$

где,

n – размер массива;

a – первая выборка;

b – вторая выборка;

S – число согласованных пар;

R – число несогласованных пар.

Значение r изменяется в интервале $r \in [-1,0; 1,0]$, где отрицательные значения свидетельствуют об обратной пропорциональной связи, а положительные о прямой пропорциональной. Величина $|r|$ характеризует силу связи между данными:

- $|r| \in [0,10; 0,30)$ – слабая связь;
- $|r| \in [0,30; 0,80]$ – умеренная / сильная связь;
- $|r| \in [0,80; 1,00]$ – очень сильная связь.

Корреляционный анализ данных относительно интенсивности энерговыделения проводился с учетом всех ячеек активной зоны.

а также входных и выходных параметров, что сформировало квадратную симметричную матрицу размерностью 42x42. Для удобства демонстрации существующих зависимостей исходная матрица была разделена на несколько: периферийные ячейки (ряды 2 и 7 активной зоны), периферийные и центральные ячейки (ряды 7, 5 и 4 активной зоны), центральные ячейки (ряды 3 и 6 активной зоны). Определенные корреляционные связи между разными ячейками представлены на рисунках 3.8 – 3.10, где цветом отмечены ячейки, для которых сила связи существенна (присутствует влияние) и H_0 о наличии корреляции не отвергается.

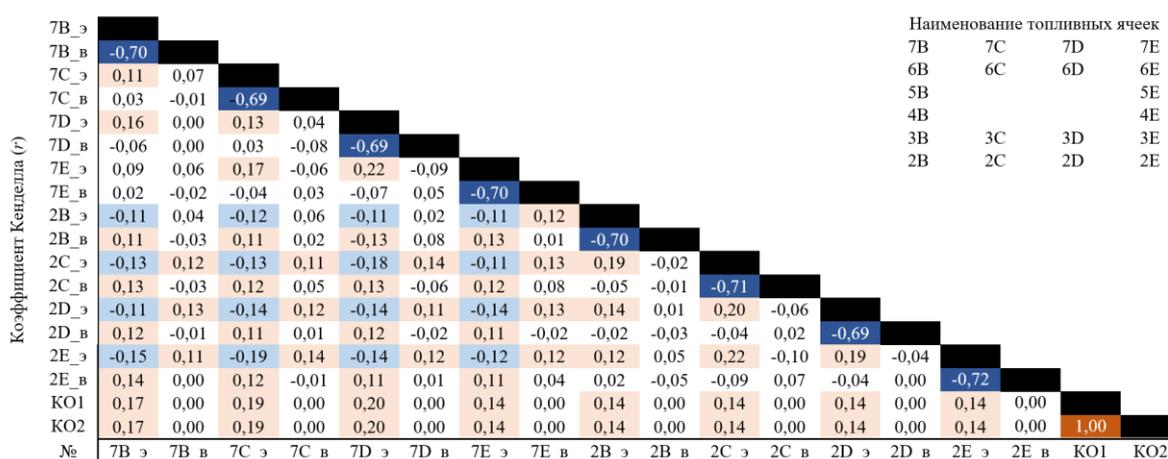


Рисунок 3.8 – Корреляционные связи между периферийными ячейками (ряды 2 и 7): постфиксы _э и _в соответствуют значениям КНРЭ и глубины выгорания

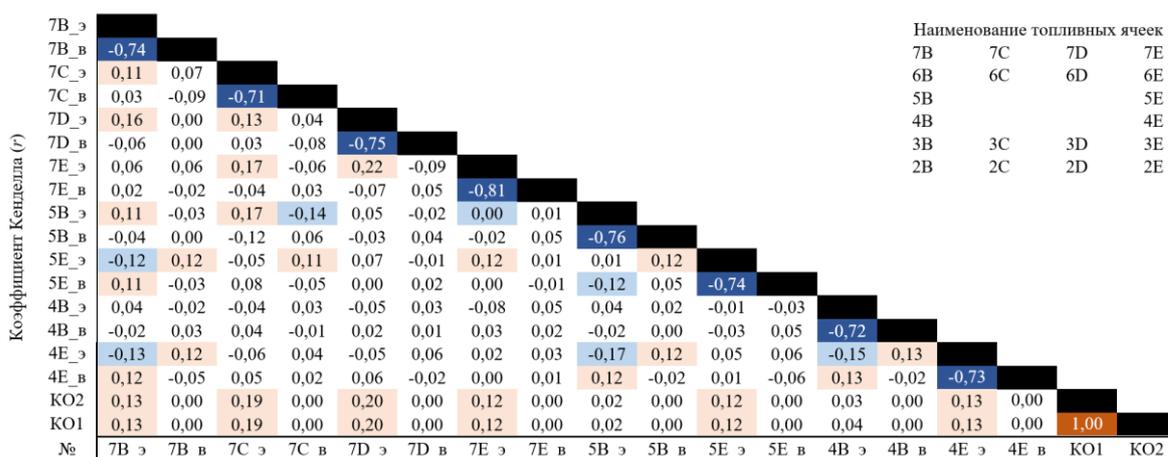


Рисунок 3.9 – Корреляционные связи между периферийными и центральными ячейками (ряды 7, 5 и 4): постфиксы _э и _в соответствуют значениям КНРЭ и глубины выгорания

– наличие слабой корреляционной связи (ниже порогового значения $r < 0,11$) между множеством ячеек является причиной высокой дисперсии распределений КНРЭ по ячейкам (рисунок 3.5б).

– РО существенно снижают энергонапряженность топливных ячеек 6В_э, 6Е_э, 3Е_э, 3В_э (рисунок 3.10) и приводят к перераспределению энерговыделения по соседним ТВС (ячейки 6С, 6D, 3С и 3D).

Аналогичный корреляционный анализ проводился для установления связей, влияющих на формирование значений запаса реактивности активной зоны реактора. Из записи (3.5) и распределений рисунка 3.7 видно, что для описания общих связей и изменений в данных, необходимы параметры, характеризующие активную зоны в целом, а не конкретные ячейки. Поэтому дополнительно были сформированы новые признаки, степень влияния и сила связи которых представлены на рисунке 3.11.

Корреляционный коэффициент	ρ								
	№	ρ	ср_в	ср_лев_в	ср_цен_в	ср_прав_в	КО1	КО2	КО3
ср_в		-0,84							
ср_лев_в		-0,12	0,32						
ср_цен_в		-0,18	0,53	0,02					
ср_прав_в		-0,11	0,36	-0,02	0,05				
КО1		-0,75	0,00	0,00	0,00	0,00			
КО2		-0,75	0,00	0,00	0,00	0,00	1,00		
КО3		-0,51	0,00	0,00	0,00	0,00	0,52	0,52	

Рисунок 3.11 – Корреляционные связи, отражающие влияние признаков на запас реактивности реактора : ср_в – среднее выгорание топлива в активной зоне; ср_лев_в, ср_цен_в, ср_прав_в – среднее выгорание левой, центральной и правой частей активной зоны реактора ИРТ-Т, соответственно;

Из картограммы видно, что на формирование значений запаса реактивности влияет как среднее содержание топлива, так и по отдельным участкам, что обусловлено комбинациями ТВС и гетерогенностью ячеек. Высокие значения степени связи характеризуют высокую чувствительность к изменениям.

3.2 Обобщение зависимостей формирования эксплуатационных характеристик активной зоны

3.2.1 Формирование значений КНРЭ в ячейках

Исходя из показателей описательной статистики, распределений и результатов корреляционного анализа относительно значений энергонапряженности ячеек необходимо отметить:

- средние значения выборок глубины выгорания, полученные на основе искусственно генерируемых компоновок, незначительно отличаются (до 3 %) от математического ожидания теоретической функции нормального распределения;
- присутствует связь между энергонапряженностью и глубиной выгорания, а также вклад компонент поправочной функции, характеризующих гетерогенность ячеек C_{cell} (разница между значениями КНРЭ таблицы 3.1), влияние РО C_{PO} (рисунок 3.6) и комбинаций отдельных ТВС C_{FAs} (рисунки 3.8 – 3.10). Это обуславливает дисперсию значений КНРЭ и запаса реактивности относительно значений глубины выгорания (рисунок 3.5 – 3.7).

В расчетно-экспериментальных исследованиях нейтронно-физических характеристик некоторых реакторных установок предложены полуэмпирические зависимости [108; 109], базирующиеся на линейных, экспоненциальных и степенных законах, применение которых зависит от конструктивных особенностей активной зоны и степени детализации геометрии расчетной модели.

Рассмотрим возможность формализации обобщенной закономерности формирования энерговыделения и запаса реактивности в активной зоне исходя из статистических распределений и представим (3.5) в качестве независимых компонент. Полученные обобщенные зависимости позволят «объяснить» прогнозные значения и их изменение на основе физически интерпретируемых коэффициентов.

$$K_{\mathcal{E}}^i \sim P^{aver} f(r) \cdot f(h, B_{core}) \cdot f(B^i, \mathbf{B}^{j,k}), \quad (3.13)$$

где,

$f(r)$ – функция пространственной энергонапряженности ячейки;

i – индекс рассматриваемой ячейки;

j, k – индексы соседних / удаленных ячеек;

$f(B^i, \mathbf{V}^{j,k})$ – функция энергонапряженности ячейки в зависимости от глубины выгорания рассматриваемой ячейки и комбинаций соседних ТВС;

$f(h, B_{core})$ – функция энергонапряженности ячейки в зависимости от глубины погружения РО и выгорания активной зоны;

Для установления аналитических закономерностей необходимо учитывать частные случаи, где одна или несколько компонент (3.5) могут быть исключены. Так, рассмотрим фиксированную ячейку и состояние с взведенными стержнями, так что $f(r) \rightarrow 1$ и $f(h = 0, B_{core} = const) \rightarrow 1$. Разделение переменных функции $f(B, \mathbf{V}^{j,k})$ в явном виде не реализуемо, так как на при формировании значения функции $f(B)$ всегда учитывается влияние некоторого набора соседних / удаленных ТВС. Это обуславливает флуктуации энергонапряженности в ячейке при одном и том же значении B (рисунок 3.5), поэтому предлагается представить $f(B, \mathbf{V}^{i,j})$ в виде:

$$f(B^i, \mathbf{V}^{j,k}) = f(B^i) + f(B^i, \mathbf{V}^j) + f(B^i, \mathbf{V}^k) \quad (3.14)$$

Степень энергонапряженности рассматриваемой ячейки зависит как от значения глубины выгорания B , так и от глубины выгорания соседних / удаленных ТВС, что представляет собой многомерную зависимость.

Из рисунка 3.5 видно, что изменение энергонапряженности от глубины выгорания для рассматриваемой упрощенной геометрии подчиняется линейному закону (рисунок 3.12а), а флуктуации значений – влияние комбинаций ТВС в активной зоне. Для качественной оценки изменений предлагается рассмотреть частный случай относительно фиксированного интервала $\Delta B^i = B_2^i - B_1^i, B_2 > B_1$, в котором флуктуации энергонапряженности есть $\Delta K = \bar{K}(\Delta B^i, \mathbf{V}^{j,k}) - K(\Delta B^i, \mathbf{V}^{j,k})$ (рисунок 3.12б).

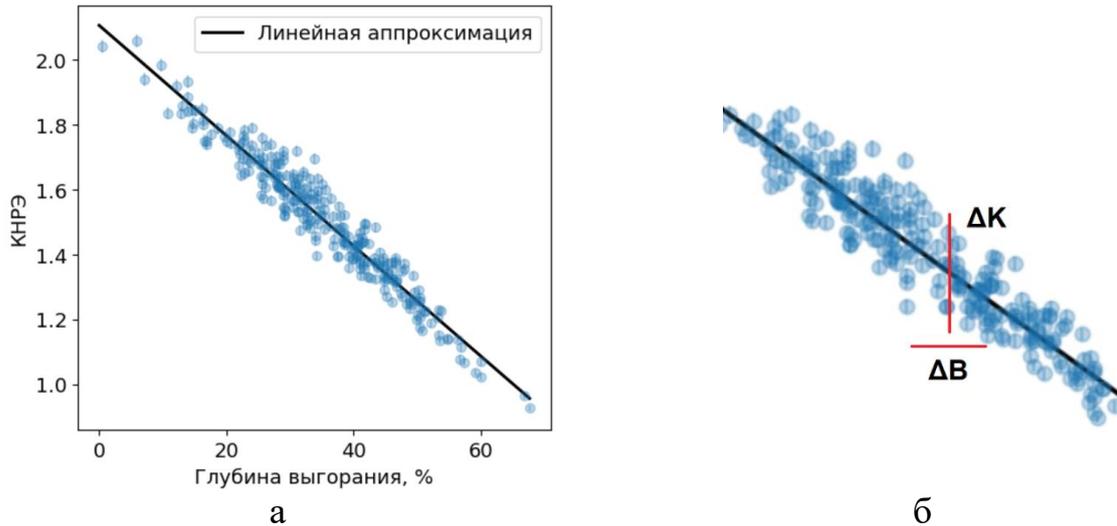


Рисунок 3.12 – Изменение энергонапряженности в зависимости от глубины выгорания и комбинаций ТВС: а – линейная аппроксимация значений без учета РО; б – изменение КНРЭ в фиксированном интервале ΔB

В общем виде изменения ΔK в интервале ΔB могут быть определены с помощью функций многомерной линейной регрессии (3.15).

$$\Delta K = f(\Delta B^i, \mathbf{B}^j) + f(\Delta B^i, \mathbf{B}^k) \quad (3.15)$$

$$\Delta K = \alpha_0 + \alpha_1 B_1 + \dots + \alpha_j B_j + \beta_0 + \beta_1 B_1 + \dots + \beta_k B_k$$

где,

α, β – коэффициенты линейной регрессии, отражающие степень «влияния» ТВС на энергонапряженность в рассматриваемой ячейке;

Функции позволяют учитывать положительное и отрицательное влияние групп ТВС, а их сумма – результирующее изменение энергонапряженности. Так, на рисунке 3.13 представлена количественная оценка влияния комбинаций ТВС на энергонапряженность ячеек 7В и 5Е для интервала ΔB , где $B \in [29 \%, 31 \%]$.

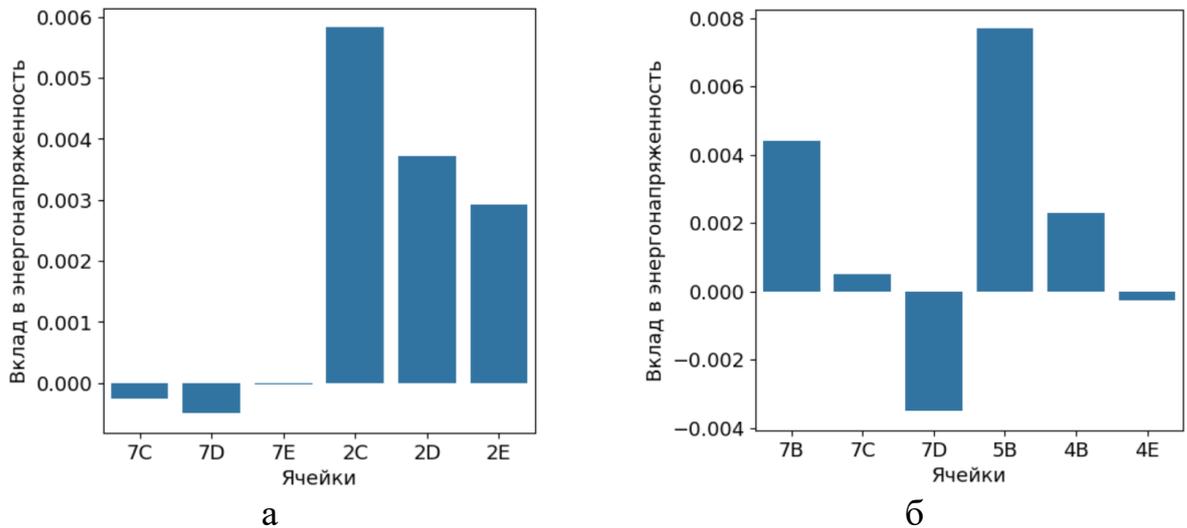


Рисунок 3.13 – Влияние глубины выгорания соседних и наиболее удаленных ТВС на энергонапряженность некоторых ячеек: а – 7В; б – 5Е

Можно видеть, что наиболее удаленные ТВС оказывают положительный вклад на величину энерговыделения в ячейках, что обусловлено перераспределением энерговыделения и согласуется с результатами, приведенными на картограммах корреляций (рисунки 3.8, 3.9)

Аналогичным образом проведем формализацию пространственной зависимости энерговыделения в активной зоне $f(r)$. Принимаем во внимание, что глубина выгорания в каждой ячейке $\bar{V}^{FAs} \approx \mu_e$ (таблица 3.1) и усреднение по всему массиву позволит минимизировать влияние флуктуаций на величину энергонапряженности в ячейке. Для каждой ячейки принимается, что РО взведены $f(h=0, B_{core} = const) \rightarrow 1$, а степень энергонапряженности каждой ячейки обусловлена только конструктивными особенностями активной зоны и ее гетерогенностью.

На рисунке 3.17 представлена зависимость КНРЭ от ячейки, характеризующая пространственную энергонапряженность, а в качестве аппроксимирующей функции использован экспоненциальный закон $f(r) = a_1 \cdot \exp(a_2 \cdot r)$, где a_1 – коэффициент масштаба, a_2 – коэффициент, характеризующий потерю интенсивности от центра к периферии.

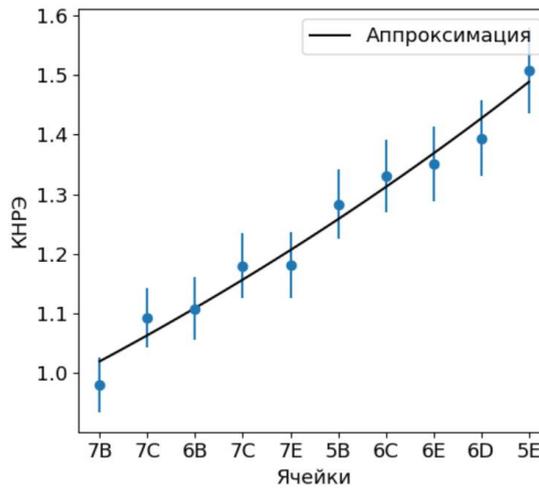


Рисунок 3.14 – Изменение пространственной теплонапряженности некоторых ячеек активной зоны

Можно видеть, полученная зависимость корректно отражает энергонапряженность правая часть активной зоны ввиду влияния бериллиевого отражателя и центральной ловушки нейтронов.

Физический закон, характеризующий влияние РО на нейтронно-физические характеристики активной зоны, имеет S-образную форму [110–112], которая на практике аппроксимируется сигмоидной функцией (3.16). Учет параметров, описывающих пространственное распределение и влияние глубины выгорания может быть реализован через соответствующие коэффициенты.

$$f(h, B_{core}) = b_1 + b_2 \cdot \frac{1}{1 + \exp(b_3 \cdot (h - b_4))} \quad (3.16)$$

где,

b_1 – коэффициент смещения функции;

b_2 – коэффициент масштаба (амплитуды) кривой;

b_3 – коэффициент, характеризующий кривизну кривой;

b_4 – коэффициент, характеризующий асимметричность;

(3.20) рассматривалась в качестве аппроксимирующей функции как для ячейки с РО, в которой происходит снижение энергонапряженности, так и для соседних ячеек. На рисунке 3.15 приведены зависимости изменения интенсивности энерговыделения в ячейках 6Е и 7С при разных положениях РО.

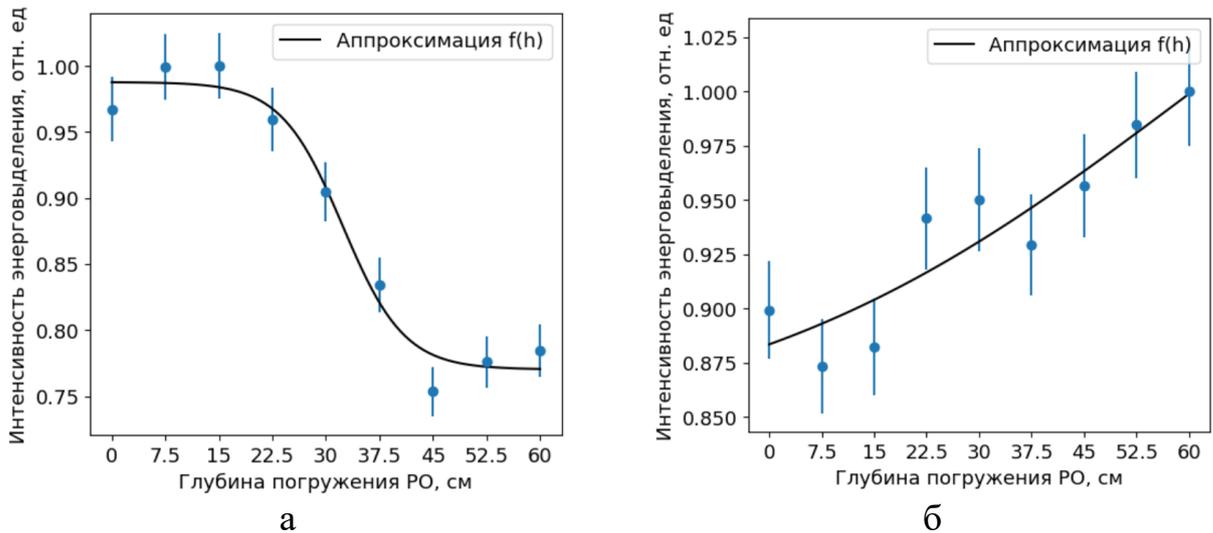


Рисунок 3.15 – Влияние положения РО на интенсивность энерговыделения в некоторых ячейках: а – 6Е; б – 7С

Характер изменения энергонапряженности в ячейке 6Е, в которой размещен РО, отражает снижение интенсивности ввиду локального увеличения доли поглощений, что согласуется с распределениями рисунка 3.6а. Можно видеть, что форма кривой обладает признаками асимметрии и участками с локальной кривизной, что обусловлено смещением «пика» поля нейтронов по высотной составляющей (рисунок 2.11) и высокой эффективностью стержней относительно центральной части активной зоны.

Из зависимости рисунка 3.15б следует, что в результате ввода КО1, КО2 в активную зону происходит рост энергонапряженности в ячейках без РО, который отражает «компенсацию» интенсивности ячеек с РО и согласуется с распределениями рисунка 3.6б. Аппроксимирующая кривая не имеет участков с кривизной ($b_3 \rightarrow 0$), что обусловлено высокой чувствительностью ячеек без РО к возмущениям поля нейтронов при введении КО1 и КО2.

3.2.2 Формирование значений запаса реактивности реактора

По аналогии с интенсивностью энерговыделения ячеек, рассмотрим возможность обобщения (3.5) на основе физических законов и частных случаев.

$$\rho \sim f(B_{core}, B^{i,j,k}) - f(h, B_{core}), \quad (3.17)$$

где,

$f(B_{core}, B^{i,j,k})$ – функция изменения запаса реактивности в зависимости от средней глубины выгорания в активной зоне и в ее отдельных участках;

i, j, k – индексы рассматриваемых участков активной зоны: левый, центральный, правый;

$f(h, B_{core})$ – функция потери запаса реактивности в зависимости от глубины погружения РО и выгорания активной зоны;

Так, рассмотрим частный случай со взведенными РО $f(h = 0, B_{core} = const) \rightarrow 1$, а компоненту $f(B_{core}, B^{i,j,k})$ представим в виде суммы:

$$f(B_{core}, B_{core}^{i,j,k}) = f(B_{core}) + f(B^{i,j,k}(B_{core})) \quad (3.18)$$

$B^{i,j,k}$ имеет зависимость от B_{core} , так как рассматриваемые сектора – часть активной зоны и для любой компоновки выполняется условие $B_{core} = \bar{B} = [B^i, B^j, B^k]$.

Из распределения рисунка 3.7а и (3.18) можем предположить, что изменение первой компоненты подчиняется линейному закону (рисунок 3.16а) и отражает потерю запаса реактивности на единицу выгорания топлива. Вклад отдельных секторов в виде $\Delta\rho$, по аналогии с (3.14), может быть представлен за счет независимых коэффициентов линейной регрессии относительно фиксированного интервала ΔB_{core} . На рисунке 3.16б представлен количественный вклад глубины выгорания в секторах активной зоны в запас реактивности реактора.

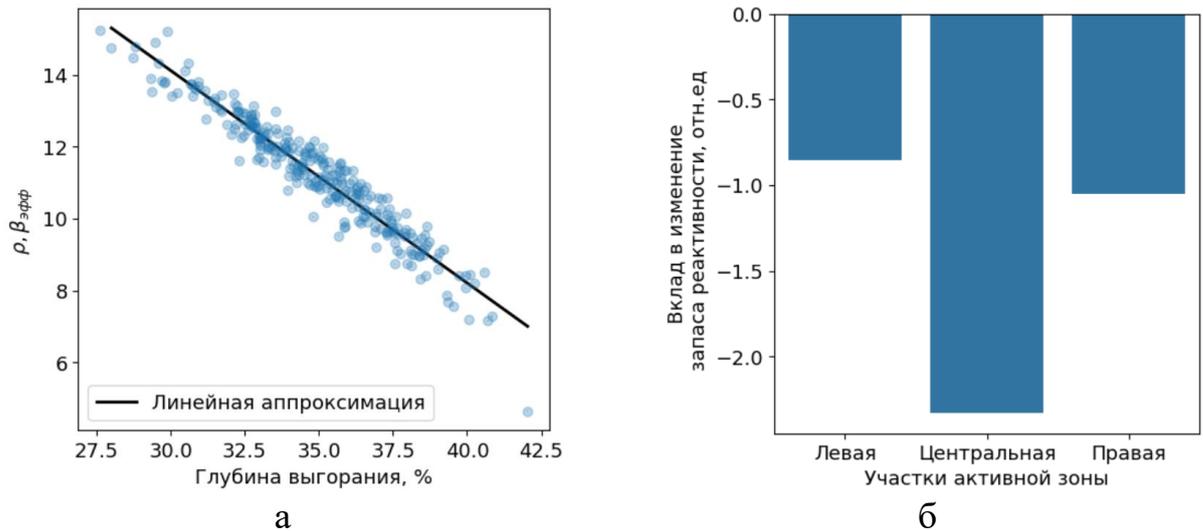


Рисунок 3.16 – Изменение запаса реактивности в зависимости от глубины выгорания по активной зоне и в отдельных секторах: а – линейная аппроксимация значений без учета РО; б – вклад компонент в изменение запаса реактивности при фиксированном интервале ΔB_{core}

Из рисунка 3.16б следует, что наибольший вклад в изменение запаса реактивности оказывает центральный сектор, что согласуется с картограммой рисунка 3.11 и обусловлено влиянием центральных бериллиевых блоков (бериллиевой ловушки).

Компонента $f(h, B_{core})$ обуславливает изменение реактивностных характеристик активной зоны от глубины погружения поглощающих стержней, что подставляет собой интегральную эффективность РО и описывается (3.20). Рассматривая несколько состояний активной зоны с разной глубиной выгорания $B_{core}=B_1$ и $B_{core}=B_2$, так что $B_1 < B_2$ возможно описать влияние степени выгорания топлива на интегральную эффективность РО. Так, на рисунке 3.17 представлены зависимости изменения физического веса КО1 и КО2 в зависимости от глубины погружения и выгорания.

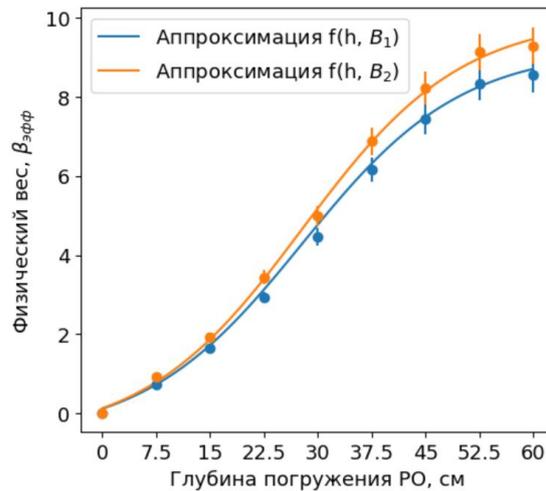


Рисунок 3.17 – Интегральная эффективность групп КО1 и КО2

Для B_2 наблюдается увеличение максимальной эффективности РО ($b_2^{B_1} < b_2^{B_2}$) и изменение степени кривизны $b_3^{B_1} < b_3^{B_2}$ (большая скорость приращения), что обусловлено увеличением плотности потока нейтронов в активной зоне для выполнения условия (3.2).

Можно видеть, что предложенные обобщенные зависимости позволяют описать особенности формирования, изменения величины энерговыделения в топливных ячейках и запаса реактивности в зависимости от множества факторов, что может быть использовано для интерпретации и объяснения выходных значений, генерируемых прогнозными моделями.

3.3 Разработка прогнозных моделей

Обобщение закономерностей формирования, распределения энерговыделения и запаса реактивности проводилось на основе частных случаев и показало многомерные зависимости относительно входных данных. Адаптация задачи (3.5) относительно глубокого обучения позволит достичь более высоких результатов, так как могут быть использованы сложные нейросетевые архитектуры. Но для прогнозов с высокой сходимостью требуется детальная настройка, что особенно затруднительно при малом размере обучающей выборки.

Предлагается, в первую очередь, рассмотреть возможности методов машинного обучения для решения задачи (3.5) относительно упрощенной геометрии [113], что позволит определять запас реактивности и распределение

энерговыделения в топливных ячейках активной зоны для любой комбинации ТВС исходя из картограммы выгорания топлива и положений РО.

3.2.1 Методы машинного обучения

Статистический анализ показал, что распределения входных, выходных данных и установленные связи объясняемы, поэтому предпочтительной парадигмой является обучение с учителем. Существует ряд алгоритмов, используемых в задачах обучения с учителем, каждый из которых имеет свои сильные и слабые стороны. Как правило, для большинства исследований рассматриваемые данные являются уникальными по типу и содержанию, что обуславливает использование эмпирического подхода при выборе обучающего алгоритма [114–117].

Для оценки применимости обучающих алгоритмов для текущей задачи были рассмотрены:

- гребневая регрессия (Ridge) – линейная регрессия с L2-регуляризацией;
- лассо регрессия (Lasso) – линейная регрессия с L1-регуляризацией;
- метод опорных векторов (SVM);
- метод ближайших соседей (KNN);
- гауссовский процесс (GPR);
- деревья решений (DTR)

Подготовка данных оказывает существенное влияние на процесс распознавания и установления шаблонов, что определяет точность модели. Для исходного набора данных были проведены:

- поиск и обработка пропущенных и «серых» значений;
- создание новых признаков, среди которых: остаток топлива по частям активной зоны (левая, центральная, правая) и в ячейках для формирования различий между типами ТВС ($\mathbf{O} = [o_1, \dots, o_{FA}]$ и т.д.);
- приведение к одному масштабу за счет стандартизации (нормировка на стандартное отклонение);

– обработка и нормировка исходных категориальных признаков – представление положений всех РО СУЗ в виде численных значений ($\mathbf{KO1} = [ko1_1, \dots, ko1_8]$ и т.д.) для возможности модели осуществлять интерполяцию на «новых» данных;

Выходных признаки задачи (3.5) относительно КНРЭ представляют собой массив значений, что рассматривается как многовыходный (многомерный) прогноз, при котором модель одновременно предсказывает несколько значений. Учитывая установленные особенности распределения энерговыделения в ячейках (рисунки 3.8–3.10) и обобщенные закономерности (3.13), которые отражают влияние множество ячеек, снижение размерности не рассматривается. Следовательно, определение каждого значения КНРЭ осуществляется на одном и том же массиве, но ожидаемый количественный вклад входных признаков будет варьироваться (рисунок 3.13).

В качестве основной техники оценки эффективности обучения была выбрана перекрестная проверка (кросс-валидация) с разделением массива на $k = 4$ частей (соотношение между обучающей и тестовой 80 : 20), где каждая рассматривается как в обучающей, так и в тестирующей выборках (рисунок 3.18), что позволяет получить «среднюю» модель с меньшей дисперсией.

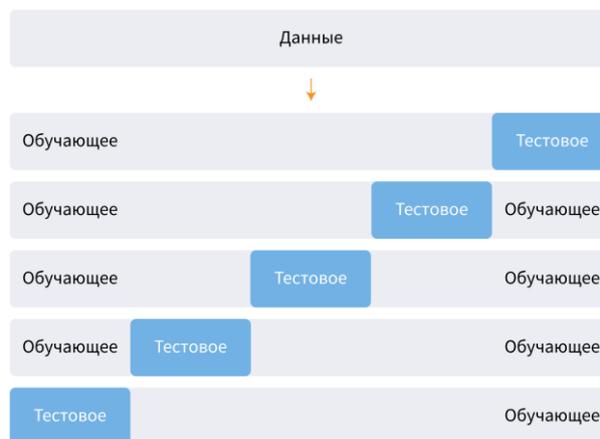


Рисунок 3.18 – Иллюстрация процесса кросс-валидации

Для количественной оценки сходимости прогнозов были выбраны метрики: коэффициент детерминации R^2 для определения общей точности (объясняемая

дисперсия) прогнозов, САО и интервалы прогнозирования. Результаты оценки работы алгоритмов на тестовых выборках представлены в таблице 3.3.

Таблица 3.3 – Результаты прогнозов «средних» моделей на тестовой выборке

Алгоритм	R^2 по ячейкам	Значения КНРЭ		Максимальное САО в ячейке
		Минимальное R^2 в ячейке	САО по ячейкам	
Ridge	0,91	0,89	0,036	0,049
Lasso	-1,53	-1,88	0,971	1,302
SVM	0,79	0,71	0,048	0,061
KNN	0,55	0,48	0,077	0,092
GPR	-3,06	-5,12	1,457	1,852
DTR	0,82	0,77	0,055	0,067

Алгоритм	Запас реактивности	
	R^2 по ячейкам	САО, $\beta_{\text{эфф}}$
Ridge	0,93	0,59
Lasso	0,49	3,18
SVM	0,88	0,87
KNN	-1,16	2,35
GPR	-0,52	–
DTR	0,91	0,69

Можно видеть, что L1-регуляризация и GPR не применимы к рассматриваемой задаче, что обусловлено невозможностью алгоритмов минимизировать ошибку на данных, имеющих схожие входные данные (значения выгорания повторяются при разных положениях РО СУЗ).

Алгоритм KNN показал достаточно низкое значение по коэффициенту детерминации при прогнозах значений КНРЭ, что объясняется чувствительностью к данным с неопределенностями (флуктуациями).

Алгоритмы SVM и DTR показали удовлетворительную сходимость при определении значений КНРЭ, что обусловлено адаптивностью алгоритмов для прогнозов на данных с численными и категориальными признаками, но наблюдается слабая устойчивость к «шумам».

В свою очередь, регрессия с L2-регуляризацией показала сходимость значений КНРЭ $R^2 = 0,91$, при САО 0,036. Сходимость прогнозных значений запаса реактивности составила $R^2 = 0,93$, при САО $0,59\beta_{\text{эфф}}$. Это свидетельствует о возможности модели устанавливать закономерности изменения в данных и

прогнозировать выходные признаки. Однако ввиду простоты модели дальнейшее конфигурирование не позволило достичь более высокого результата.

На рисунках 3.19 – 3.20 представлены прогнозные возможности алгоритма Ridge для определения значений КНРЭ и запаса реактивности.

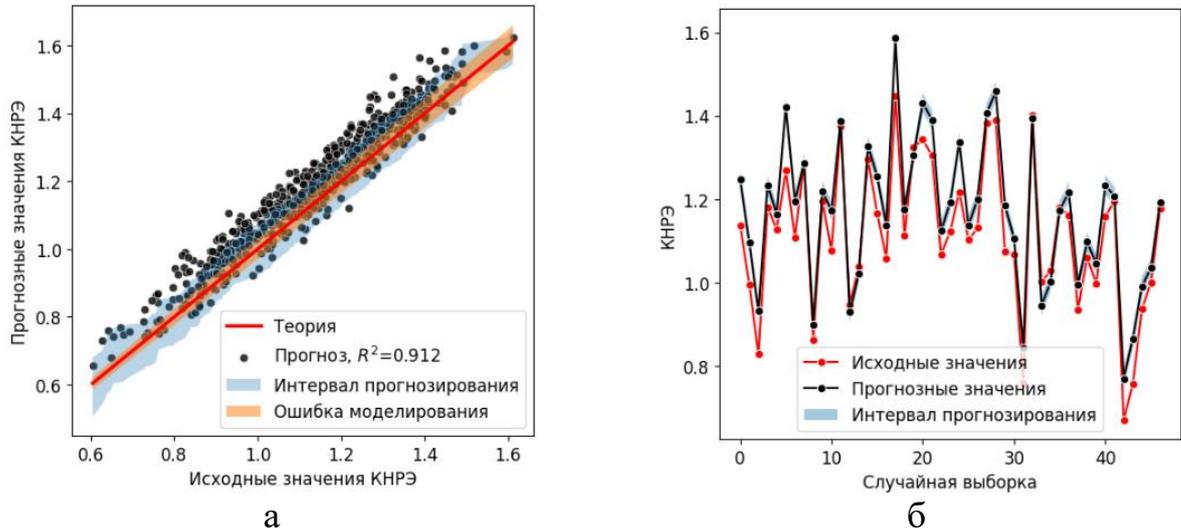


Рисунок 3.19 – Прогнозные возможности алгоритма Ridge для определения КНРЭ: а – сходимость прогнозов и истинных значений; б – предсказания на случайной тестовой выборке

Из рисунков 3.19 следует, что выходные значения Ridge-модели имеют выбросы, характеризующие нестабильность прогнозов, а также общее (коллективное) отклонение значений от теоретической кривой, что обуславливает эффект «смещения».

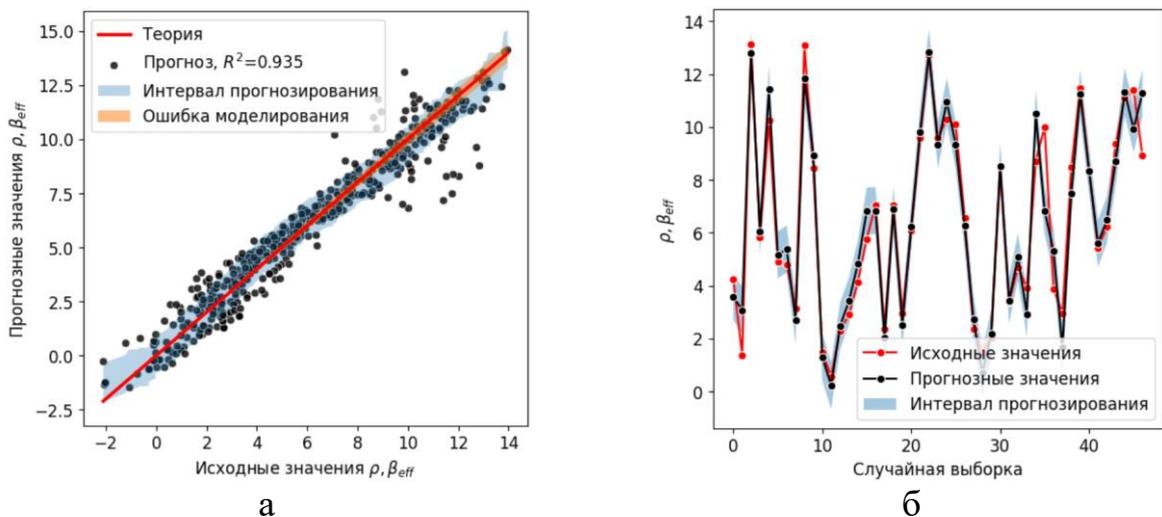


Рисунок 3.20 – Прогнозные возможности алгоритма Ridge для определения запаса реактивности: а – сходимость прогнозов и истинных значений; б – предсказания на случайной тестовой выборке

Как можно видеть, прогнозные значения запаса реактивности имеют сходство с теоретической прямой, а также описывают характер значений на случайной выборке. Присутствуют «вылеты» в положительную и отрицательную стороны, что характеризует неопределенность модели при прогнозах значений запаса реактивности, превышающих $6,0 \beta_{эфф}$.

Использование одиночных Ridge-моделей (таблица 3.3) позволяет прогнозировать значения КНРЭ и запаса реактивности исходя из картограммы выгорания и положения РО, однако наблюдаются отклонения значений от теоретических (тестовых) ввиду высокой дисперсии или смещения (bias), что свидетельствует о нестабильности (неопределенности) моделей для некоторых типов данных.

3.2.2 Ансамблирование прогнозных моделей

Предлагается перейти к более детальной разработке моделей на основе инструментов ансамблирования [118], которые подразумевают использование методов объединения алгоритмов для решения проблемы «смещение-дисперсия» [119] и повышения точности и стабильности прогнозов.

Основные подходы к созданию ансамблей моделей:

- бэггинг (bagging, **Bootstrap Aggregating**) – усреднение результатов прогнозов нескольких моделей, зачастую реализуется за счет использования кросс-валидации;
- бустинг (boosting) – последовательность «слабых» моделей, каждая из которых исправляет ошибки предыдущей за счет взвешивающих функций;
- стэкинг (stacking) – комбинирование предсказаний нескольких моделей с помощью метамоделли.

Бустинг и стэкинг могут быть использованы для рассматриваемой задачи, однако рассмотренные одиночные модели показали неустойчивость к исходным данным. Поэтому их комбинирование на основе метамоделли потребует детальной настройки и поиска оптимального состава моделей, что представляет собой

длительный итерационный процесс и осложнит дальнейшую интерпретацию результатов.

Gradient Boosting – основа современных методов бустинга, реализующая оптимизацию функции потерь через градиентный спуск на основе деревьев решений. В зависимости от задач предусматривается регуляризация потерь и оптимизация скорости [120]. Функция потерь (1.4) с учетом процесса градиентного бустинга с деревьями решений (GBR) имеет вид:

$$\begin{aligned} \theta^* &= \arg \min \left[\sum_I^N L(y, \hat{f}(x_i, \theta)^K) \right], \\ \hat{f}(x)^K &= \sum_{k=1}^K f_k(x), \quad f_k \in \Omega, \\ \hat{f}(x)^K &= \hat{f}(x)^{K-1} + f_K(x) \end{aligned} \quad (3.19)$$

где,

K – количество деревьев решений;

Каждое прогнозное значение (3.19) в структуре ансамблей деревьев решений представляет собой реализацию добавочного обучения (вклад предыдущих прогнозов), что позволяет повысить общую точность выходных значений:

Ансамбли на основе деревьев решений имеют множество параметров для варьирования, среди которых: скорость обучения, количество деревьев, глубина и т.д. Оценка влияния параметров и подбор оптимальных значений проводилась с помощью итерационного сеточного поиска параметров GridSearch [121]. На рисунке 3.21 приведены результаты предсказаний на тестовой выборке для GBR-модели при наиболее оптимальных параметрах.

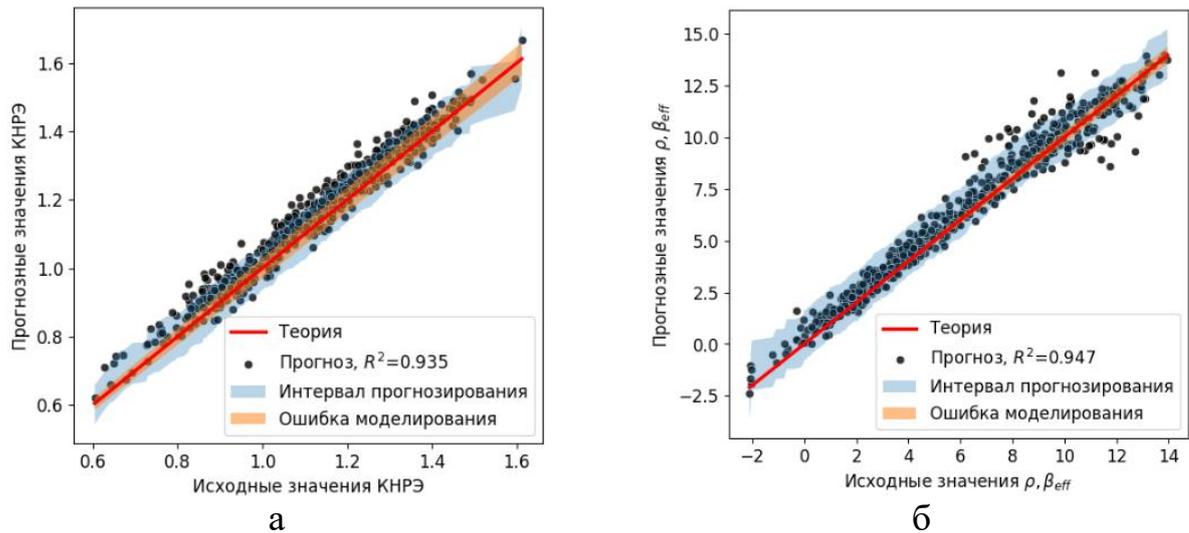


Рисунок 3.21 – Тестирование GBR-модели: а – сходимость тестовых и прогнозных значений КНРЭ; б – сходимость тестовых и прогнозных значений запаса реактивности

Можно видеть, что наблюдается снижение дисперсии значений и общее смещение прогнозов относительно теоретической кривой (рисунок 3.21). Средняя сходимость КНРЭ по ячейкам составила $R^2 = 0,94$, при CAO 0,025 (снижение на 28 % относительно Ridge-модели). Точность определения значений запаса реактивности составила $R^2 = 0,95$, при CAO 0,47 $\beta_{\text{эфф}}$ (снижение на 20 % относительно Ridge -модели).

Для дальнейшего повышения прогнозной силы модели была рассмотрена конфигурация за счет штрафной регуляризации деревьев решений. Предложена L2-регуляризация, которая ранее показала хорошую сходимость:

$$\theta^* = \arg \min \left[\sum_{i=1}^N L(y, \hat{f}(x_i, \theta)) + \sum_{k=1}^K \omega(f_k) \right], \quad (3.20)$$

$$\omega(f_k) = \frac{1}{2} \lambda \sum_{j=1}^T \gamma_j^2$$

где,

K – количество деревьев решений;

$\omega(f_k)$ – регуляризация деревьев;

γ – вес в листе.

Прогнозные возможности GBR-модели с использованием L2-регуляризации приведены на рисунке 3.22.

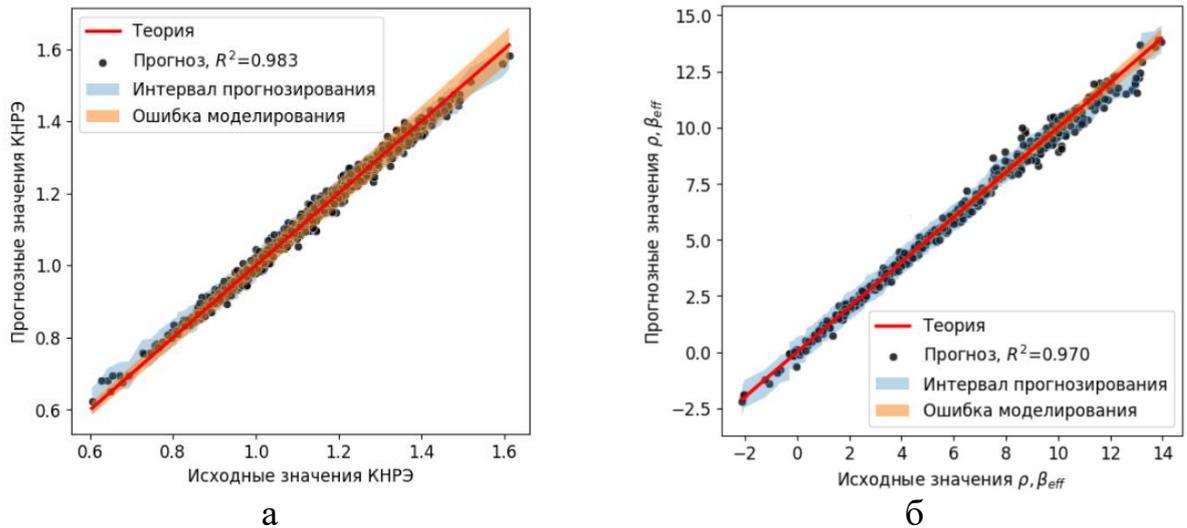


Рисунок 3.22 – Тестирование GBR-модели с L2-регуляризацией: а – сходимость тестовых и прогнозных значений; б – прогноз на случайной выборке

Можно видеть, что добавление L2-регуляризации позволило снизить дисперсию прогнозных значений. Средняя сходимость значений КНРЭ по ячейкам составила $R^2=0,98$, при САО 0,014 (снижение на 46 % относительно GBR-модели). Точность определения значений запаса реактивности составила $R^2=0,97$, при САО $0,33 \beta_{эфф}$ (снижение на 30 % относительно GBR-модели).

На рисунке 3.23 представлены остатки прогнозов $\hat{K}_j - K_j$ (residuals) для моделей GBR и GBR + L2 относительно прогнозов КНРЭ и запаса реактивности.

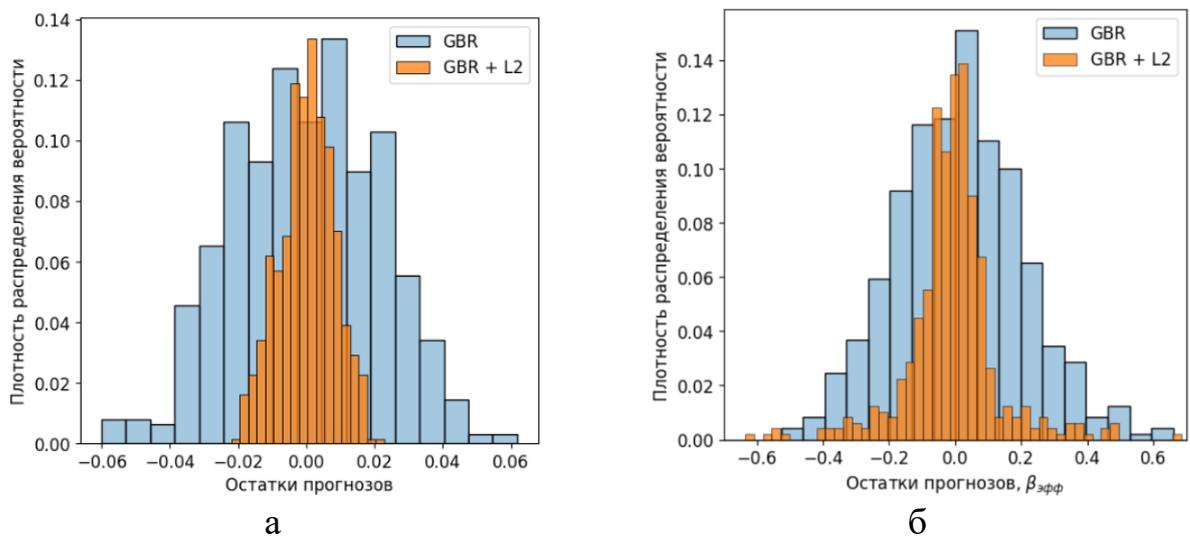


Рисунок 3.23 – Сравнение остатков прогнозов GBR-моделей: а – значения КНРЭ; б – значения запаса реактивности

Из распределений рисунка 3.23а следует, что остатки моделей представляют собой независимые случайно распределенные величины – выполняется свойство регрессионных остатков (модель адекватна). Также можно видеть снижение дисперсии предсказываемых значений, которое позволило уменьшить диапазон разброса значений более чем в 2,4 раза. Использование модели GBR + L2 снизило диапазон разброса значений запаса реактивности более чем в 1,6 раз.

На рисунке 3.24 приведены интервалы прогнозирования значений в ячейках активной зоны при $\alpha = 0,05$ (с вероятностью 95 %), характеризующие диапазон выходного значения.

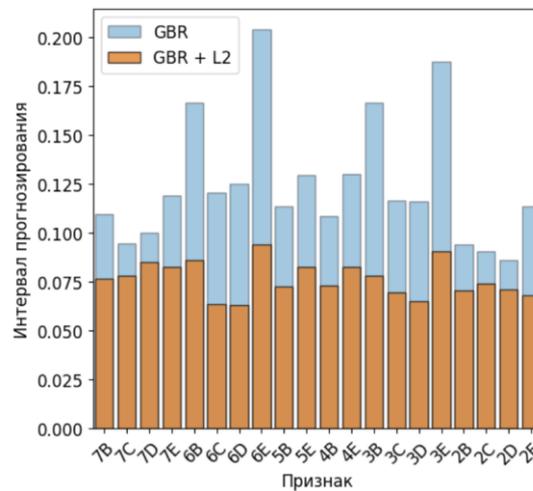


Рисунок 3.24 – Интервалы прогнозирования значений КНРЭ:

а – GBR-модель; б – GBR-модель + L2-регуляризация

Можно видеть, что ширины интервалов для каждого признака отличаются незначительно при среднем значении 0,06. Снижение относительно модели GBR составило в среднем 1,9 раз. Интервал прогнозирования значений запаса реактивности уменьшился в 1,5 раз и составляет $1,13 \beta_{эфф}$.

Для наглядной демонстрации прогнозных возможностей алгоритма в таблице 3.4 представлено распределение энерговыделения в ячейках и значение запаса реактивности, полученные путем моделирования в ПС MCU-PTR и с помощью GBR-модели.

Таблица 3.4 – Сравнение значений энергонапряженности и запаса реактивности на тестовой выборке

Тестовая картограмма, КО1, КО2 = 30 см

MCU-PTR				GBR -модель					
Запас реактивности									
$\rho = 10,35 \beta_{эфф}$				$\rho = 10,15 \beta_{эфф}$					
КНРЭ									
	В	С	D	E		В	С	D	E
7	0,98	1,28	1,34	1,57		0,98	1,27	1,31	1,54
6	1,24	1,59	1,53	1,64		1,23	1,58	1,51	1,62
5	1,19			1,29		1,19			1,29
4	1,24			1,41		1,24			1,40
3	0,99	1,40	1,34	0,84		0,99	1,40	1,33	0,81
2	1,08	1,02	0,77	1,08		1,06	0,99	0,77	1,09

CAO: 0,012

MAO: 0,038

Таким образом, можно видеть, что разброс выходных значений модели относительно действительных (тестовых) удовлетворяют интервалам прогнозирования рисунка 3.24. Погрешность определения запаса реактивности также не превышает установленного интервала.

3.2.3 Многозадачное обучение

Статистический анализ и адаптация инструментов машинного обучения для прогнозирования энерговыделения осуществлялась на примерах данных, описывающих состояние активной зоны реактора ИРТ-Т при использовании упрощенной геометрии ТВС.

В простейшем случае для перехода к прогнозам в детальной геометрии необходима повторная подготовка исходных данных, содержащих аналогичное (или большее) количество примеров, чтобы учесть вклад твэльной и азимутальной составляющих согласно (3.6). После чего необходим повторный эмпирический подбор обучающего алгоритма на новой выборке, что накладывает сложности к подготовке и ограничения к универсальности подхода.

Для максимально эффективного использования данных и временных ресурсов целесообразно адаптировать зависимости распределения

энерговыведения в упрощенной геометрии для прогнозов в детальной. В практике переноса «знаний» при разном уровне детализации используется несколько общепринятых подходов, каждый из которых подразумевает использование нейросетевых структур, так как требуется установление связей в нескольких массивах одновременно:

- перенос обучения – подход при котором первая модель, обученная на общих данных, переносится и переобучается на детальных;
- полуконтролируемое обучение – подход при котором одна модель используется для генерации псевдо-разметки, а вторая использует комбинацию данных;
- многозадачное обучение [122] – представляет собой разновидность обучения с учителем и самообучения, при которой используются два массива данных и модель с общими слоями, но разными выходами.

Для качественной реализации первого подхода требуется большая исходная выборка и разнообразие входных данных. Поэтому данный подход нашел наибольшее применение для классификации изображений на общих классах и подклассах. При полуконтролируемом обучении используется псевдо-разметка данных, которая повышает общую обучаемость, но является причиной увеличения общей (накапливаемой) ошибки, что сложно нивелировать при малых массивах данных.

Поэтому для повышения универсальности подхода к прогнозированию энерговыведения в активной зоне, предлагается осуществить переход от машинного обучения к глубокому за счет реализации многозадачного обучения на основе нейросетевой архитектуры рисунка 3.25.

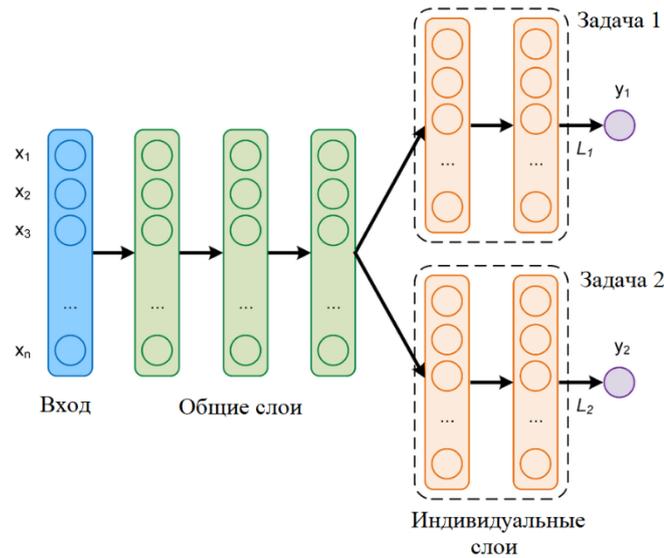


Рисунок 3.25 – Архитектура ИНС для многозадачного обучения
(MLP_MTL)

Формирование связей между упрощенной и детальной геометрией (1.3) реализовано через общие и индивидуальные слои ИНС, а регуляризация процесса обучения относительно двух массивов осуществляется за счет взвешенной функции потерь (3.21).

$$\min_{\theta} L_{tot} = \min_{\theta} \sum_t^T \omega_t L_t(y, \hat{f}(x, \theta)), \quad (3.21)$$

где,

L – функция потерь;

ω – взвешивающий коэффициент;

T – количество задач.

Для формирования исходного массива данных детальной геометрии использовались компоновки, сформированные для упрощенной геометрии, из которых случайным образом были выбраны 48 примеров. Выбранные компоновки моделировались в ПС MCU-PTR с учетом положений РО КО1, КО2 = 30 см (наибольшая энергонапряженность). Далее формировались тренировочные и тестовые массивы, полученное соотношение между массивами детальной и упрощенной геометрии при одних и тех же положения РО составило $\approx 1:5$ ($\approx 2\%$ относительно всей выборки упрощенной геометрии). На рисунке 3.26 представлено сравнение значений КНРЭ в некоторых ячейках активной зоны для

упрощенной и детальной геометрии, которые характеризуют вклад азимутальной координаты в КНРЭ.

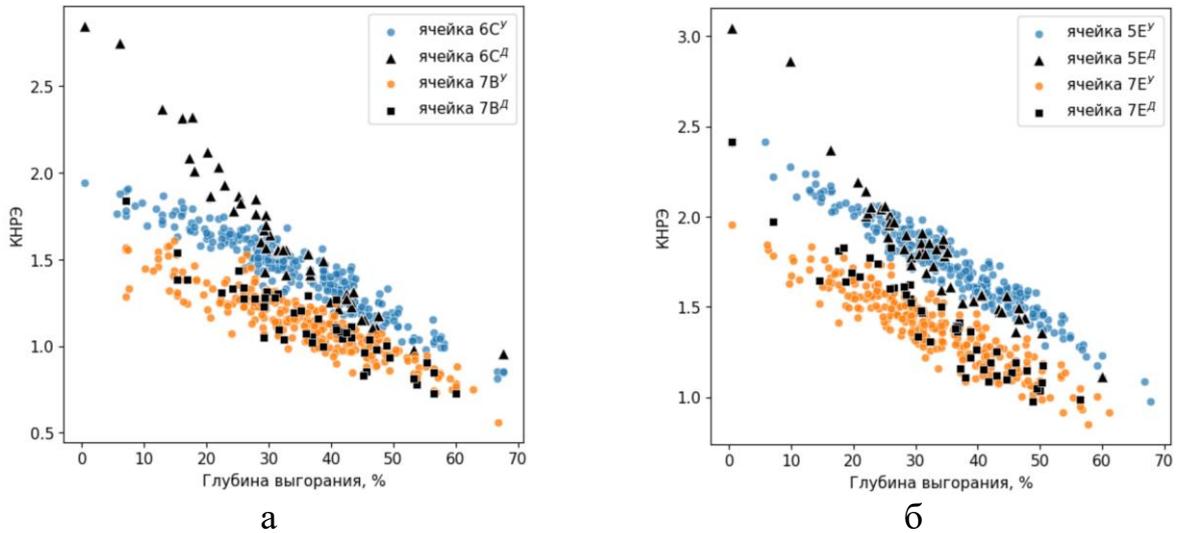


Рисунок 3.26 – Сравнение значений КНРЭ при упрощенной (У) и детальной (Д) геометрии в некоторых ячейках: а – ячейки 6С (центр) и 7В (периферия); б - ячейки 5Е (центр) и 7Е (периферия)

Из рисунка 3.26 следует, что для периферийных ячеек разница в энергонапряженности незначительна и составляет 5 – 10 %, но для центральных ячеек разница существенна и достигает 30 – 50 %. Сводные значения КНРЭ во всех ячейках при упрощенной и детальной геометрии приведены в таблице 3.5.

Таблица 3.5 – Сравнение значений КНРЭ в ячейках при упрощенной и детальной геометрии ТВС

№	Средние значения КНРЭ		Максимальные значения КНРЭ	
	У	Д	У	Д
7В	1,13	1,13	1,61	1,83
7С	1,27	1,31	1,74	2,01
7Д	1,38	1,43	1,96	2,41
7Е	1,39	1,41	1,94	2,13
6В	1,14	1,86	1,69	1,86
6С	1,44	1,62	1,94	2,85
6Д	1,55	1,62	2,07	2,61
6Е	1,44	1,37	2,11	2,43
5В	1,33	1,40	1,81	2,18
5Е	1,73	1,80	2,41	3,04
4В	1,32	1,42	1,92	2,32
4Е	1,68	1,68	2,27	2,87
3В	1,10	1,12	1,58	1,73

№	Средние значения КНРЭ		Максимальные значения КНРЭ	
	У	Д	У	Д
3С	1,35	1,63	1,93	2,82
3D	1,40	1,51	1,92	2,56
3E	1,35	1,39	1,98	2,39
2B	1,09	1,11	1,55	1,89
2C	1,22	1,26	1,88	1,99
2D	1,23	1,24	1,78	1,96
2E	1,25	1,27	1,91	2,09

При использовании геометрии с азимутальными секторами ТВС наблюдается существенный рост максимальных значений КНРЭ, что обусловлено высокой энергонапряженностью на скруглениях и гранях вблизи бериллиевого отражателя. Это согласуется с расчетными неравномерностями в ТВЭлах, представленными на рисунках 2.14 – 2.15. Наибольший прирост наблюдается в ячейках 6С и 3С, расположенных вблизи бериллиевой ловушки активной зоны реактора ИРТ-Т и составил более 47 %. Средний прирост ОКНРЭ по всем топливным ячейкам составил 20 %, при наибольшем значении в ячейке 5Е, которое составило $K_V=3,04$, что свидетельствует о высокой энергонапряженности.

Наибольший вклад азимутальных секторов наблюдаются при глубине выгорания топлива < 15 %, что требует соответствующего учета при формировании топливных компоновок.

Чтобы использовать ранее сформированный массив (все положения РО в упрощенной геометрии) при обучении ИНС предлагается общая схема рисунка 3.27. В этом случае большое количество данных упрощенной геометрии позволяет устанавливать закономерности в общих слоях ИНС, влияя на весовые параметры слоев и обучаемость модели. Повторяемость данных детальной геометрии не приводит к эффекту «переобучения», т.к нет пересечений между тренировочной и тестовыми примерами, что обеспечивает процесс многозадачного обучения.

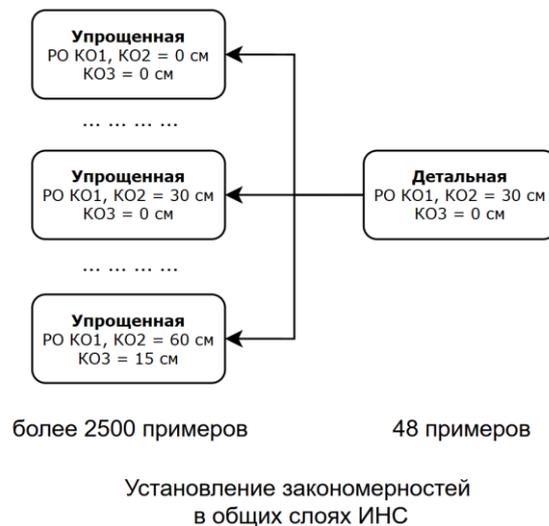


Рисунок 3.27 – Общая схема использования массивов упрощенной и детальной геометрий для обучения ИНС

Общие параметры ИНС для прогнозирования численных значений КРНЭ в ячейках:

- скрытые линейные слои (от 1 до 3 штук) с активационной функцией ReLU (нелинейное преобразование нейронов слоев);
- выходной слой со сглаживающей сигмоидной активационной функцией;
- количество нейронов в входных и выходных слоях фиксировано, количество нейронов в скрытых слоях может быть определено эмпирически – зависимость от задачи и сложности данных;
- метрики функции потери: тренировочная ошибка и обратное распространение на основе среднеквадратичной ошибки для чувствительности к выбросам; тестовая ошибка – CAO для удобства анализа и интерпретации результатов.

В качестве исходного подхода при подборе количества нейронов были выбраны правила «от входного к выходному», где учитываются размеры входного и выходного слоев и «степени двойки», чтобы эффективно использовать вычислительные ресурсы при матричных вычислениях GPU. Перебор параметров осуществлялся с помощью GridSearch.

По аналогии с GBR-моделью, в процессе обучения ИНС использовалась кросс-валидация для учета данных всего массива и оптимального подбора

взвешивающих коэффициентов функции потери. В таблице 3.6 представлены результаты тестирования модели MLP_MTL при разных взвешивающих коэффициентах, усредненные по кросс-валидационным выборкам. С целью сравнения эффекта обучения при многозадачной нейросетевой архитектуре в таблицу добавлены результаты обучения классической ИНС для массивов упрощенной и детальной геометрии.

Таблица 3.6 – Результаты обучения ИНС с разными весовыми коэффициентами

ω		CAO по ячейкам		R^2 по ячейкам	
У	Д	У	Д	У	Д
1,0*	0,0*	0,020*	–	0,97*	–
0,9	0,1	0,021	0,056	0,97	0,84
0,8	0,2	0,021	0,058	0,97	0,84
0,7	0,3	0,021	0,059	0,97	0,84
0,6	0,4	0,021	0,054	0,97	0,85
0,5	0,5	0,021	0,052	0,97	0,86
0,4	0,6	0,022	0,048	0,97	0,87
0,3	0,7	0,023	0,053	0,97	0,85
0,2	0,8	0,026	0,059	0,96	0,84
0,1	0,9	0,027	0,062	0,96	0,83
0,0**	1,0**	–	0,069**	–	0,72**

*обучение массивов только на данных упрощенной геометрии

**обучение массивов только на данных детальной геометрии

Из результатов таблицы 3.6 следует, что использование классической ИНС для предсказания распределения энерговыделения в детальной геометрии позволяет достичь общей точности не более $R^2=72\%$, при CAO 0,069 на ячейку. Применение многозадачной архитектуры и взвешенной функции потери дает возможность увеличить общую точность прогнозов до $R^2=87\%$, при CAO 0,048 на ячейку, что на 31 % ниже по сравнению с классической ИНС.

На рисунках 3.28-3.29 представлено сопоставление результатов MLP_MTL-модели с тестовой выборкой для периферийной и центральной ячеек.

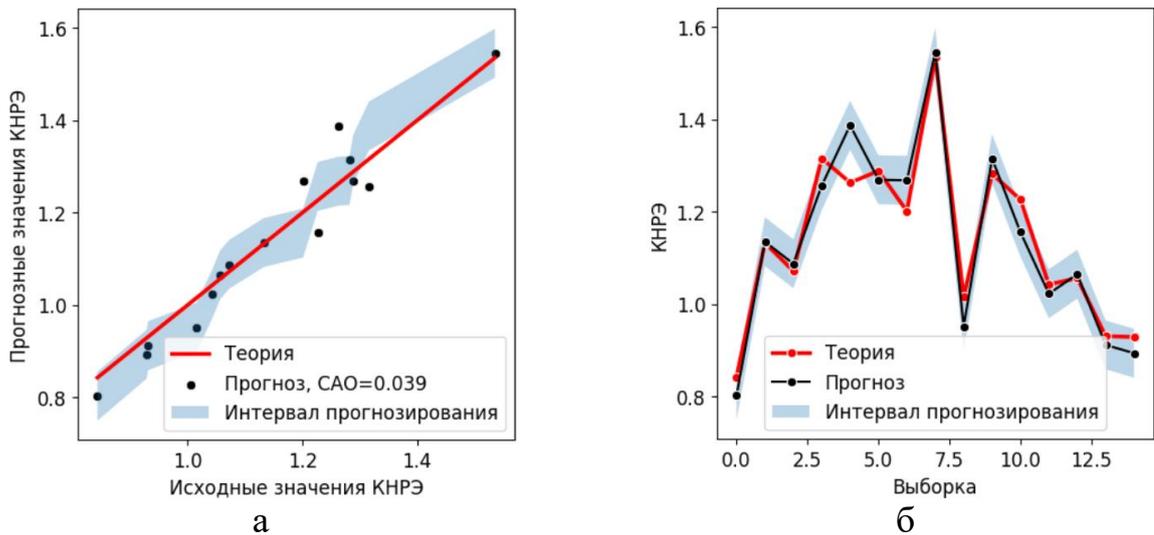


Рисунок 3.28 – Результаты MLP_MTL-модели для периферийной ячейки (7В): а – сходимость тестовых и прогнозных значений; б – прогноз на тестовой выборке

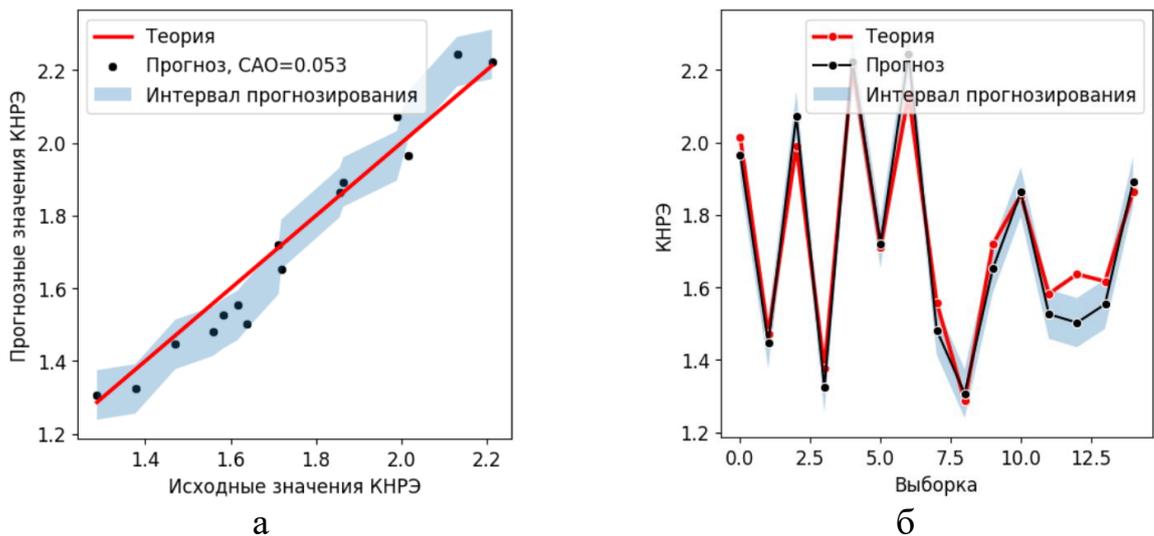


Рисунок 3.29 – Результаты MLP_MTL-модели для центральной ячейки (5С): а – сходимость тестовых и прогнозных значений; б – прогноз на тестовой выборке

Модель MLP_MTL описывает характер распределения значений в ячейках, однако сходимость результатов для периферийных ячеек выше, что обусловлено высокой энергонапряженностью центральных ТВС при детальной геометрии, поэтому признаки из упрощенной не могут оказать существенного обучающего эффекта.

Так как CAO в энергонапряженных ячейках более чем на 30 % выше, чем для периферийных требуется дополнительная доработка алгоритма. Улучшение

результатов возможно за счет увеличения размера обучающей выборки с последующим дообучением, или повышения степени обучаемости модели, что требует разработки и конфигурирования более сложной архитектуры ИНС.

Использование глубоких ИНС позволяет устанавливать более сложные связи между признаками, однако зачастую приводит к проблеме исчезающего градиента и деградации результатов, что в условиях недостатка данных представляет собой сложную оптимизационную задачу.

Одним из подходов, используемым в задачах распознавания и классификации изображений является обучение на остатках (Residual Learning)[123], где используется трансформация (3.22), позволяющая использовать более глубокие слои без ухудшения результатов.

$$\hat{f}(x, \theta) = F(x, \theta) + x, \quad (3.22)$$

где,

$F(x, \theta)$ – остаток, прогнозируемый моделью.

В рассматриваемой задаче проблема затухающего градиента обусловлена малым размером обучающей выборки, что влияет на темп и качество установления скрытых связей. Предлагается использовать остаточное обучение для повышения обучаемости модели за счет использования не только общих «качеств» упрощенной и детальной геометрии, но и различий (рисунок 3.26). Обучающий алгоритм сопоставляет остатки между распределениями, функция потерь и итоговый прогноз представляются как:

$$\begin{aligned} \min_{\theta} \sum L(y^D - y^Y, \hat{f}(x, \theta)^D - \hat{f}(x, \theta)^Y), \\ \min_{\theta} \sum L(res, \widehat{res}), \\ \hat{f}(x, \theta)^D = \widehat{res} + \hat{f}(x, \theta)^Y, \end{aligned} \quad (3.23)$$

где,

res, \widehat{res} – исходные и прогнозируемые остатки (разница между данными при детальной и упрощенной геометрии).

В этом случае реализуется процесс дообучения за счет переноса слоев и весов исходной MLP_MTL в новый Residual-блок, а также добавления нового

индивидуального слоя для прогноза остатков. Архитектура Residual-блока представлена на рисунке 3.30.

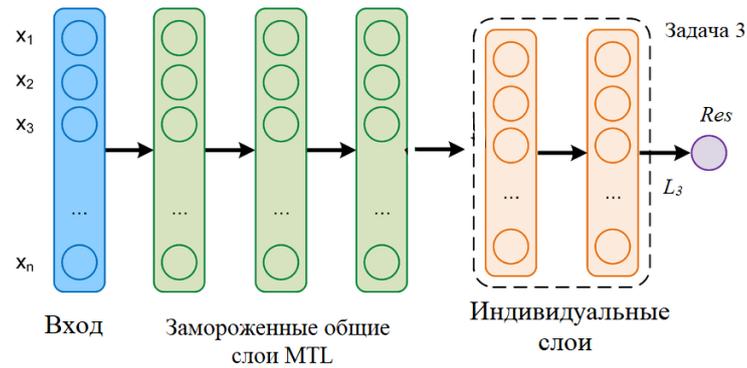


Рисунок 3.30 – Residual-блок для MLP_MTL-модели

При необходимости конфигурирования, индивидуальные слои MLP_MTL-модели могут быть использованы в процессе обучения совместно с Residual-блоком за счет добавления (3.23), как компоненты к (3.21).

При обучении Residual-блока разбиение тренировочной и тестовой выборок не изменялось, чтобы элементы тестового массива не участвовали в обучении и не оказывали влияния на количественную оценку сходимости результатов. На рисунке 3.31 представлена сравнительная оценка темпов обучения моделей MLP_MTL + Residual-блок и MLP_MTL.

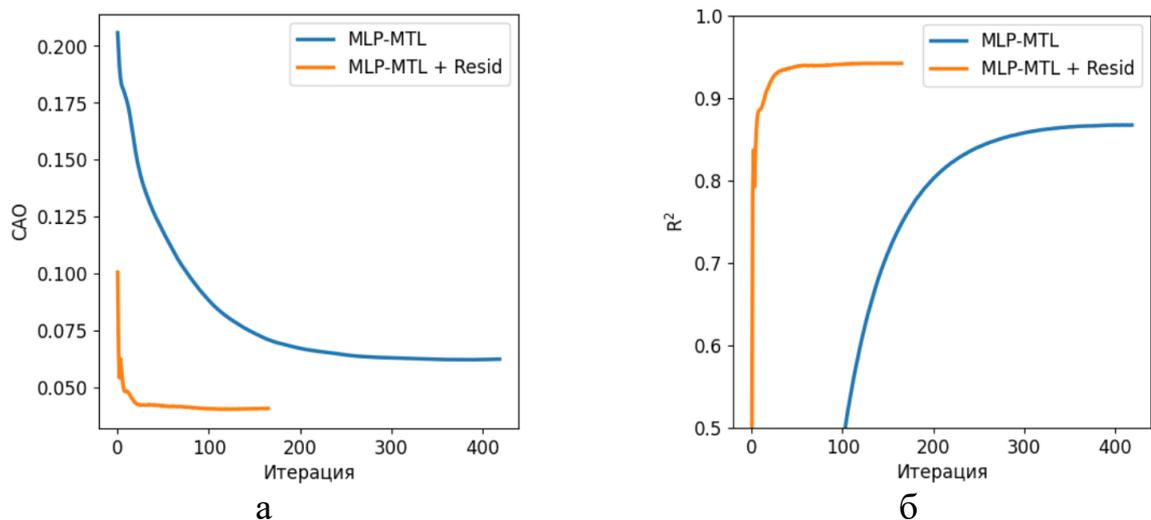


Рисунок 3.31 – Сходимость результатов на тестовой выборке для моделей MLP_MTL и MLP_MTL + Residual-блок

Можно видеть, что ввиду переноса весовых коэффициентов слоев ИНС, значения CAO для модели MLP-MTL + Residual-блок с первых итераций

значительно ниже и достигает минимального значения 0,037 уже к 100-й итерации. Это в 1,4 раз меньше, чем при использовании исходной многозадачной MLP_MTL архитектуры. При этом общая точность прогнозирования значений по ячейкам R^2 увеличивается с 0,87 до 0,93.

На рисунках 3.32-3.33 представлены прогнозные возможности модели MLP_MTL + Residual-блок относительной тестовой выборки в периферийной и центральной ячейках активной зоны.

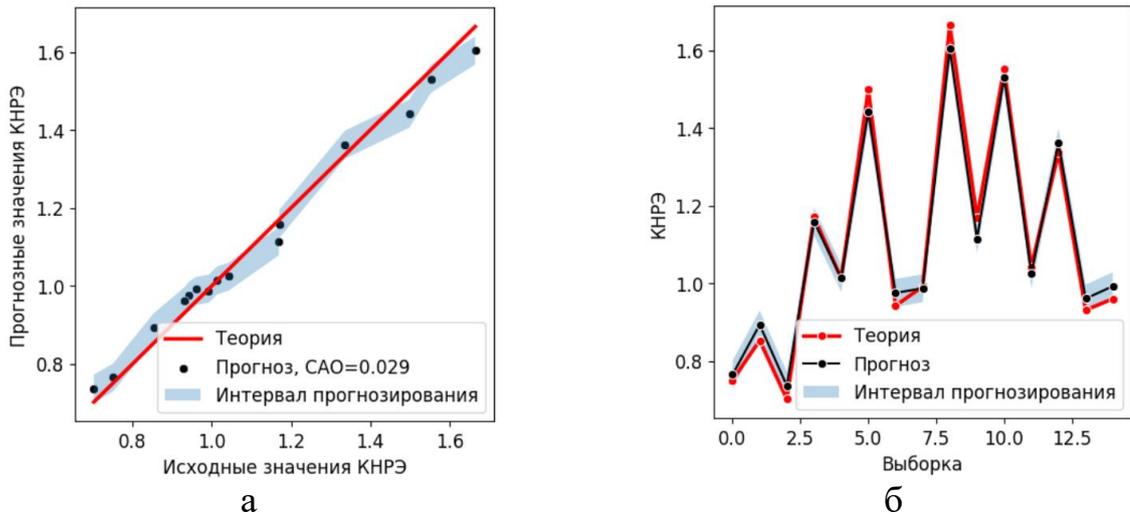


Рисунок 3.32 – Результаты модели MLP_MTL + Residual-блок для периферийной ячейки (7В): а – сходимость тестовых и прогнозных значений; б – прогноз на тестовой выборке

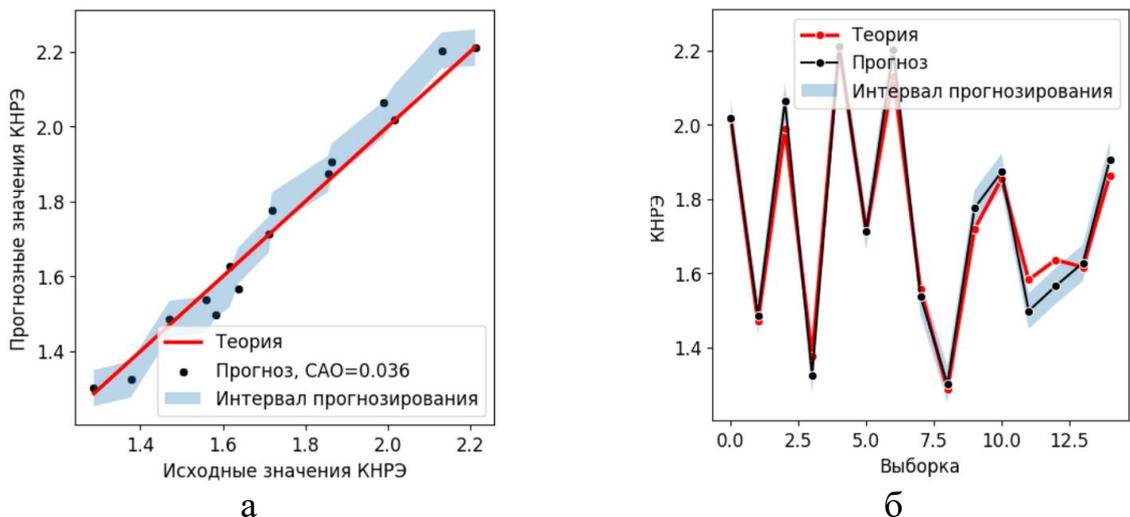


Рисунок 3.33 – Результаты MLP_MTL + Residual-блок для центральной ячейки (5С): а – сходимость тестовых и прогнозных значений; б – прогноз на тестовой выборке

Сравнивая прогнозные распределения моделей MLP_MTL (рисунки 3.28-3.29) и MLP_MTL + Residual-блок можно сделать вывод, что CAO прогнозирования снизилась более чем на 26 % и 33 % для периферийной и центральной ячеек, соответственно. Это свидетельствует о положительном эффекте алгоритма дообучения на основе остатков.

Для наглядной демонстрации работы алгоритма в таблице 3.7 представлены картограммы энерговыделения, полученные в ПС MCU-PTR и предсказанные моделью MLP_MTL + Residual-блок.

Таблица 3.7 – Прогнозные возможности нейросетевой модели (MLP_MTL + Residual-блок) для определения распределения энерговыделения в активной зоне

	MCU-PTR				MLP_MTL + Residual-блок			
	В	С	Д	Е	В	С	Д	Е
7	1.01	1.46	1.36	1.38	1.01	1.49	1.34	1.40
6	0.98	1.70	1.55	1.80	1.02	1.72	1.55	1.77
5	1.19			2.21	1.24			2.21
4	1.45			1.51	1.44			1.45
3	1.05	1.38	1.46	1.36	1.12	1.35	1.49	1.37
2	1.12	1.28	1.19	0.77	1.13	1.26	1.17	0.78

CAO: 0,023
MAO: 0,069

Из таблицы 3.7 следует, что прогнозы в ячейках удовлетворяют установленным пределам, разработанная модель на основе ИНС MLP_MTL + Residual-блок позволяет описывать общий характер распределений с учетом наиболее энергонапряженных участков в твэлах.

В процессе обучения и тестирования модели были использованы 48 топливных компоновок, что свидетельствует о высокой степени обучаемости предложенной архитектуры ИНС. Это позволяет осуществлять быстрый переход от одного геометрического разбиения ТВС к другому, оценивать характеристики топливных компоновок активной зоны, а также определять предельные значения КНРЭ в наиболее интенсивных участках твэлов.

3.4 Верификация и валидация прогнозных моделей

Несмотря на то, что разработанные модели показали удовлетворительную сходимость на тестовых данных этого недостаточно для подтверждения их устойчивости и применимости для решения реальных задач, которые могут иметь отличия от обработанных тестовых примеров или выходить за пределы диапазона обучения модели. Рассматриваемые в разделе подходы к верификации и валидации направлены на:

- интерпретацию моделей, то есть переход от «черного ящика» к объяснимому ИИ;
- оценку соответствия исходным данным и стабильности работы для подтверждения корректности реализации;
- определение физической «осмысленности» прогнозных значений;
- сопоставление результатов с эталонными решениями и экспериментальными данными.

3.4.1 Интерпретация результатов и верификация структуры моделей

Решения, принимаемые моделями машинного обучения, основываются на внутренних процессах и установленных закономерностях. Интерпретируемость и объяснимость выходного результата – ключевой этап при интеграции таких моделей в производственных цикл, который позволяет понять какие признаки и свойства влияют на прогноз.

В настоящее время наибольшее практическое распространение для интерпретации результатов работы моделей машинного обучения получил подход SHAP (Shapley Additive Explanation Values) [124], основанный на концепции значений Шепли [125]. Учитывается эффективность каждого отдельного входного признака в формирование выходного результата, что позволяет интерпретировать модель:

$$\hat{f}(\mathbf{X}) = g(\mathbf{X}') = E | \hat{f}(\mathbf{X}) | + \sum_{j=1}^N \varphi_j \quad (3.24)$$

где,

$g(\mathbf{X})$ – «объясняющая» функция;

φ – вклад признака

N – входные признаки модели;

$E|\hat{f}(\mathbf{X})|$ – математическое ожидание прогнозной модели при N признаков.

Количественная разница между двумя прогнозами с разным количеством входных признаков в виде условной вероятности описана согласно (3.26).

$$\begin{aligned} g(S) &= E[\hat{f}(x_S) | \hat{f}(x_N)], \\ \Delta(S+1, S) &= g(S+1) - g(S), \\ \Delta(S+1, S) &= E[\hat{f}(x_{S+1}) | \hat{f}(x_N)] - E[\hat{f}(x_S) | \hat{f}(x_N)] \end{aligned} \quad (3.25)$$

где,

S – количество входных признаков на основе которых сделан прогноз;

$g(S)$ – прогноз на основе S признаков.

На основе SHAP-концепции проводилась оценка вклада входных признаков на формирование выходных значений КНРЭ и запаса реактивности, их физическая интерпретация и согласованность с результатами статистического анализа и установленными закономерностями. Для этого случайным образом была выбрана топливная компоновка, не участвующая в процессе обучения, относительно которой рассматривались два состояния: все РО взведены; КО1, КО2 погружены на 60 см. Это позволит определить каким образом модель формирует значения запаса реактивности и энерговыделения в ячейках без влияния поглощающих стержней и оценить локальные эффекты «искажения» энергонапряженности. В таблице 3.8 приведена исходная картограмма, распределения энерговыделения и значения запаса реактивности для рассматриваемых состояний.

Таблица 3.8 – Исходная картограмма загрузки и значения КНРЭ, запаса реактивности при разных положениях РО

		Глубина выгорания, %															
		В	С	Д	Е			КНРЭ									
7		25,09	50,73	28,39	49,53			0,99	1,17	1,27	1,21			0,99	1,24	1,35	1,21
6		20,06	21,97	40,89	20,21			0,88	1,15	1,07	1,62			0,71	1,19	1,10	1,29
5		48,86			25,88			0,98			1,24			1,00			1,25
4		25,13			56,50			1,24			1,85			1,25			1,86
3		10,96	44,85	46,86	14,59			1,31	1,17	1,01	1,46			1,08	1,21	1,06	1,15
2		25,25	41,98	46,89	44,10			1,16	1,26	1,04	0,83			1,16	1,34	1,09	0,82

РО КО1, КО2, КО3 = 0 см

КО1, КО2 = 60 см

Запас реактивности

$\rho = 8,01 \beta_{эфф}$

$\rho = 0,27 \beta_{эфф}$

КНРЭ

		РО КО1, КО2, КО3 = 0 см				КО1, КО2 = 60 см			
		В	С	Д	Е	В	С	Д	Е
7		0,99	1,17	1,27	1,21	0,99	1,24	1,35	1,21
6		0,88	1,15	1,07	1,62	0,71	1,19	1,10	1,29
5		0,98			1,24	1,00			1,25
4		1,24			1,85	1,25			1,86
3		1,31	1,17	1,01	1,46	1,08	1,21	1,06	1,15
2		1,16	1,26	1,04	0,83	1,16	1,34	1,09	0,82

Можно видеть, что модель прогнозирует снижение энергонапряженности в ячейках с группами РО КО1 и КО2 (ячейки 6В, 3В и ячейки 6Е и 3Е) в среднем на 25 %, при увеличении энергонапряженности остальных ячеек на 4–7 %. На рисунках 3.34 – 3.35 приведены оцененные SHAR-значения для состояний активной зоны с взведенными и погруженными РО КО1, КО2 относительно ячеек 7Д и 6Е.

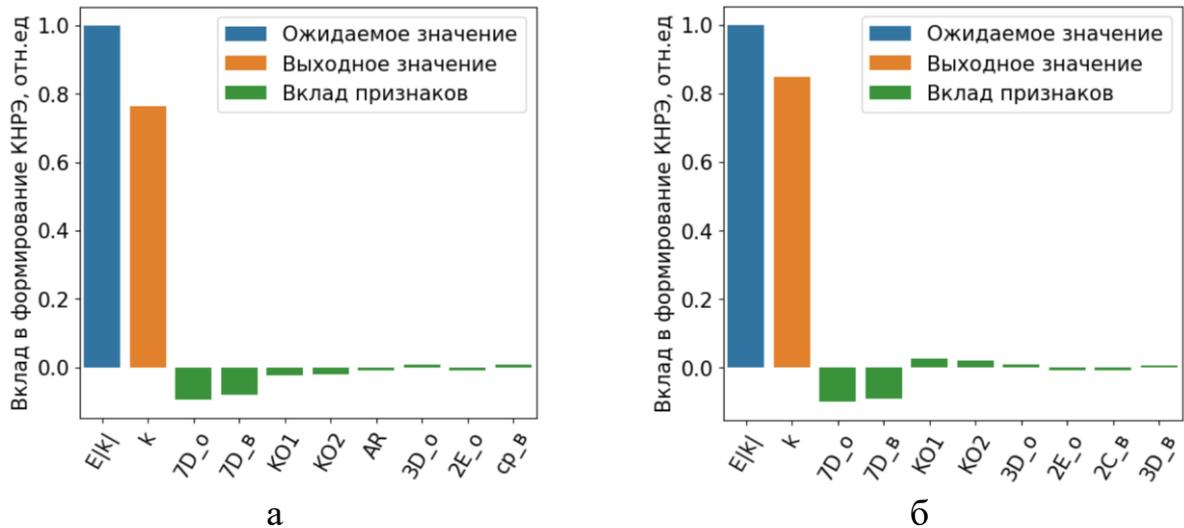


Рисунок 3.34 – Формирование значений КНРЭ в ячейке 7D:

а – РО взведены; б – РО KO1, KO2 = 60 см

При взведенных РО изменение выходного значения относительного математического ожидания составило минус 23 %, что согласуется с зависимостью рисунка 3.12а и обусловлено высокой глубиной выгорания топлива в ячейке (47,9 %). Признаки, характеризующие положения РО также имеет отрицательный вклад – «компенсация» энергонапряженности за счет локального влияния признаков «KO1» и «KO2» отсутствует. Наблюдается влияние удаленных ячеек 3D и 2E на формирование выходного значения, что согласуется с предложенной зависимостью (3.15).

В случае полного введения РО KO1 и KO2 наблюдается рост выходного значения, отклонение относительного математического ожидания составило минус 15 % (прирост составил ≈ 35 % относительно состояния с взведенными РО). Наблюдается перераспределение энерговыделения и положительный вклад признаков KO1 и KO2, что согласуется с зависимостью рисунка 3.15б.

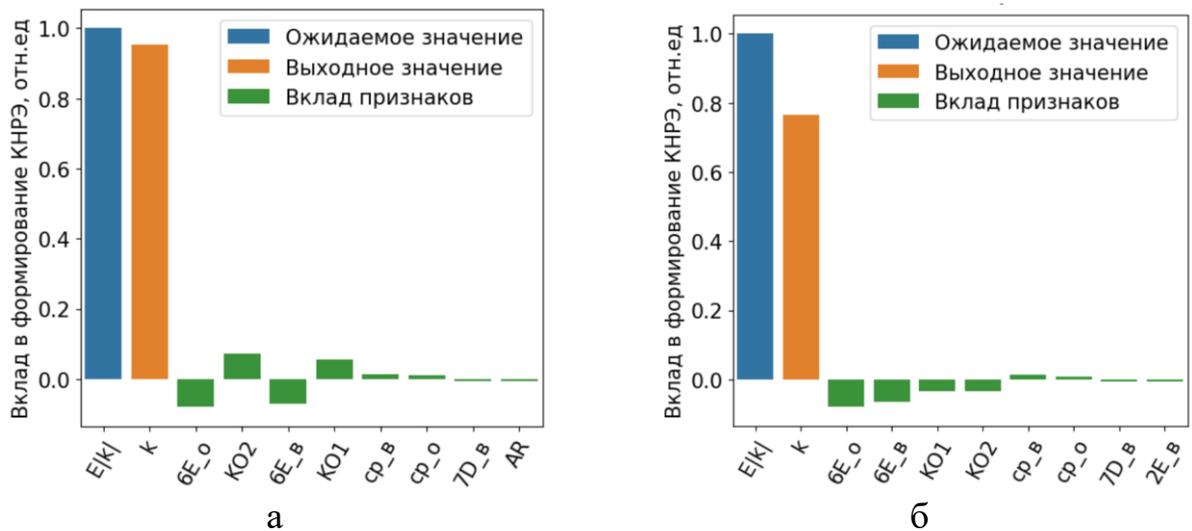


Рисунок 3.35 – Формирование значений КНРЭ в ячейке бЕ:

а – РО взведены; б – КО1, КО2 = 60 см

При взведенных РО изменение выходного значения относительного математического ожидания составило минус 5 %, что обусловлено высокой глубиной выгорания топлива в ячейке (48,9 %) – одноименные признаки имеют отрицательный вклад. Признаки «КО1» и «КО2» оказывают положительный вклад, что свидетельствует об отсутствии локального влияния на энергонапряженность.

Для случая, когда КО1 и КО2 полностью погружены наблюдается существенное снижение энергонапряженности в ячейке до минус 24 % относительно математического ожидания. Количественный вклад от признаков «КО1» и «КО2» – отрицательный, что отражает локальный эффект от поглощающих стержней и согласуется с зависимостью рисунка 3.15а.

SHAP-значения, характеризующие вклад в формирование значений запаса реактивности реактора для рассматриваемых состояний приведены на рисунке 3.36.

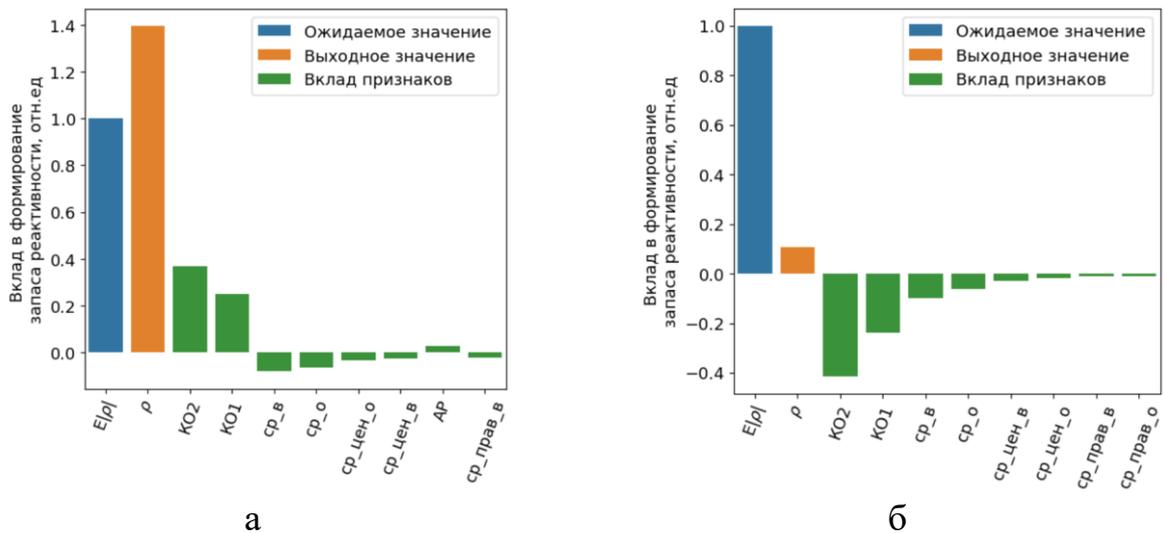


Рисунок 3.36 – Формирование значений запаса реактивности на основе SHAR-значений: а – РО взведены; б – КО1, КО2 = 60 см

Можно видеть, что при полностью взведенных РО выходное прогнозное значение больше математического ожидания на 40 % – положительный вклад от признаков «КО1» и «КО2», что свидетельствует об отсутствии влияния поглощающих стержней на реактивные характеристики. При этом наблюдается отрицательный вклад от признаков «sr_v» и «sr_o», что обусловлено существенным выгоранием топлива в активной зоне ($\approx 40\%$) и согласуется с зависимостями рисунка 3.16 и картограммой рисунка 3.11.

В случае погружения РО КО1 и КО2 происходит существенное снижение прогнозного значения относительно математического более чем на 85 %, что обусловлено физическим процессом поглощения нейтронов и описывается интегральной характеристикой рисунка 3.17

SHAR-тест показал, что количественный вклад входных признаков в формирование значений КНРЭ и запаса реактивности полностью соответствует исходным данным. Присутствует согласованность со статистическими зависимостями и сформированными закономерностями, что обуславливает интерпретируемость и физическую объяснимость разработанных прогнозных моделей.

Для определения устойчивости и чувствительности предлагается оценить адаптивность прогнозов при «шумных» входных признаках. Была реализована

трансформация исходных данных за счет поправочной функции «шума» $x' = x + N(0, I)$, на основе которых прогнозировались выходные признаки. На рисунке 3.37 приведены остатки (разница между исходными и шумными данными) входных и прогнозных значений.

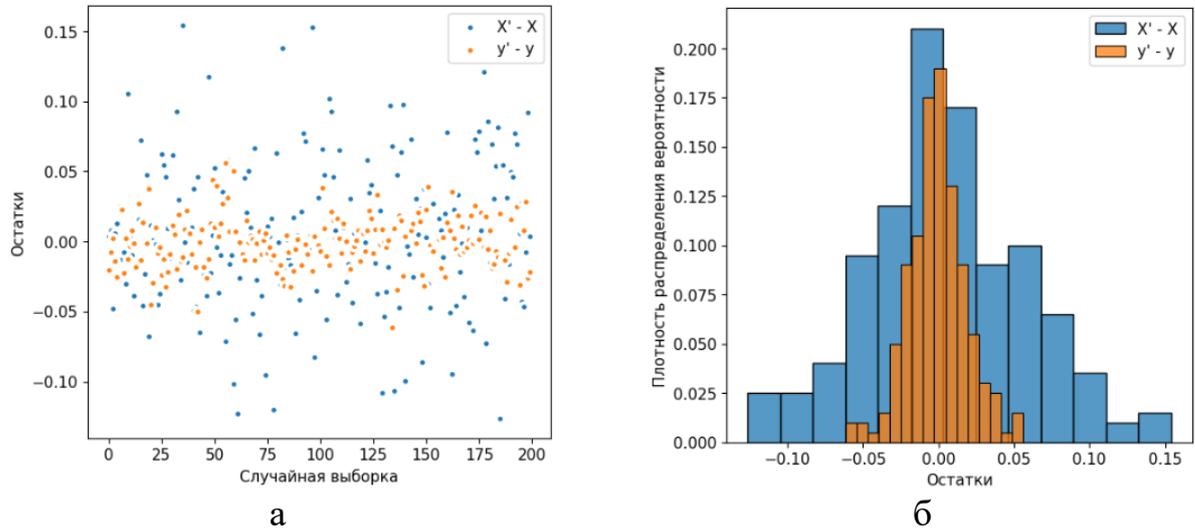


Рисунок 3.37 – Распределение остатков исходных и прогнозных данных

Можно видеть, что остатки выходных данных распределены «нормально», что свидетельствует о соответствующей адаптивности модели. Вылеты и смещения отсутствуют – обеспечивается стабильность и чувствительность к незначительным изменениям.

Таким образом, на основе проведенных оценок показано, что разработанные прогнозные модели интерпретируемы – формируемые прогнозы объясняемы и физически «осмысленны». Тестирование на «шумных» данных показало, что прогнозы устойчивы к вылетам и чувствительны к незначительным изменениям.

3.4.2 Валидация на основе эталонных расчетов и экспериментальных данных

Сопоставление с эталонными расчетами и экспериментальными данными реактора ИРТ-Т позволит определить точность работы моделей и установить область их применения для прогнозного определения эксплуатационных характеристик активной зоны.

Под эталонными расчетами понимаются результаты моделирования реакторных топливных загрузок, полученные в ПС MCU-PTR. В процессе

расчетного сопровождения учитываются реальные положения РО СУЗ, что позволит провести кросс-валидацию прогнозных значений КНРЭ и запаса реактивности. Предлагается сопоставлять значения по нескольким эксплуатационным состояниям в рамках каждой кампании, чтобы учесть процесс выгорания топлива, разные положения РО и установить диапазон входных параметров, в котором формируются наиболее уверенные прогнозы.

Для сравнения результатов моделирования и прогнозов случайным образом были выбраны 24 состояния активной зоны за период работы реактора с 05.2021 г по 12.2023 г. Основные характеристики некоторых состояний активной зоны приведены в таблице 3.9.

Таблица 3.9 – Некоторые экспериментальные состояния активной зоны реактора ИРТ-Т за период 2021-2023 г

Дата	Положения РО, см			$\rho, \beta_{эфф}$	K_v	Среднее выгорание, %
	КО1	КО2	КО3			
17.05.2021	49	49	0	10.12	1.69	31.88
21.06.2021	47	47	0	8.67	1.65	34.18
04.10.2021	45	45	0	9.42	1.48	31.70
07.12.2021	35	35	0	7.03	1.44	35.44
18.01.2022	49	49	0	10.16	1.46	30.87
29.03.2022	33	33	0	7.52	1.71	35.11
26.04.2022	60	60	0	10.47	1.86	30.74
05.09.2022	34	32	0	7.56	1.84	35.43
15.11.2022	48	48	0	10.59	1.67	31.20
10.01.2023	32	32	0	7.15	1.70	34.46
07.02.2023	60	60	15	10.69	1.65	30.18
03.04.2023	47	47	0	8.69	1.59	33.45
15.05.2023	33	33	0	6.81	1.58	36.43

На рисунке 3.38 представлено сопоставление прогнозных и экспериментальных значений относительно запаса реактивности и экспериментальной критичности реактора ИРТ-Т.

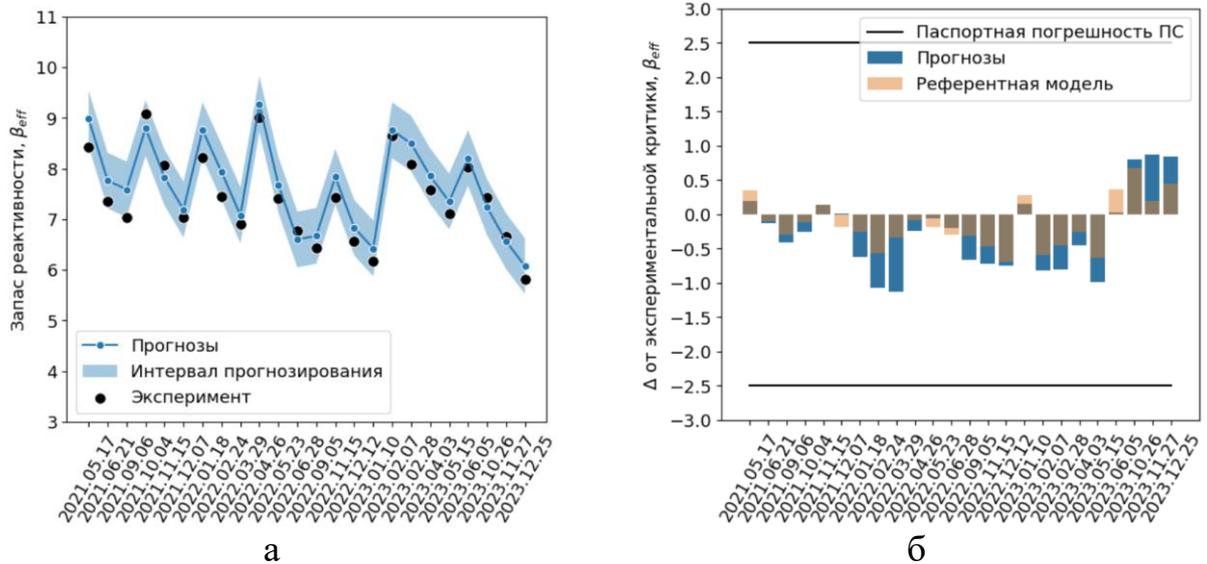


Рисунок 3.38 – Прогнозирование размножающих свойств активной зоны реактора ИРТ-Т: а – запас реактивности; б – отклонение от экспериментальной критичности

Можно видеть, что характеры изменения прогнозные и экспериментальные значения запаса реактивности (рисунок 3.38а) имеют согласованность, экспериментальные точки входят в интервал прогнозирования модели, а общая сходимость по критерию R^2 составила 0,94, при САО 0,39 $\beta_{эфф}$. Из рисунка 3.38б следует, что отклонение от экспериментальной критичности не превышает 0,51 $\beta_{эфф}$ и удовлетворяет установленному пределу паспортной погрешности ПС MSU-PTR.

На рисунке 3.39 приведено сопоставление прогнозных и расчетных значений КНРЭ в левой (5В) и правой (5Е) частях активной зоны для рассматриваемых эксплуатационных циклов.

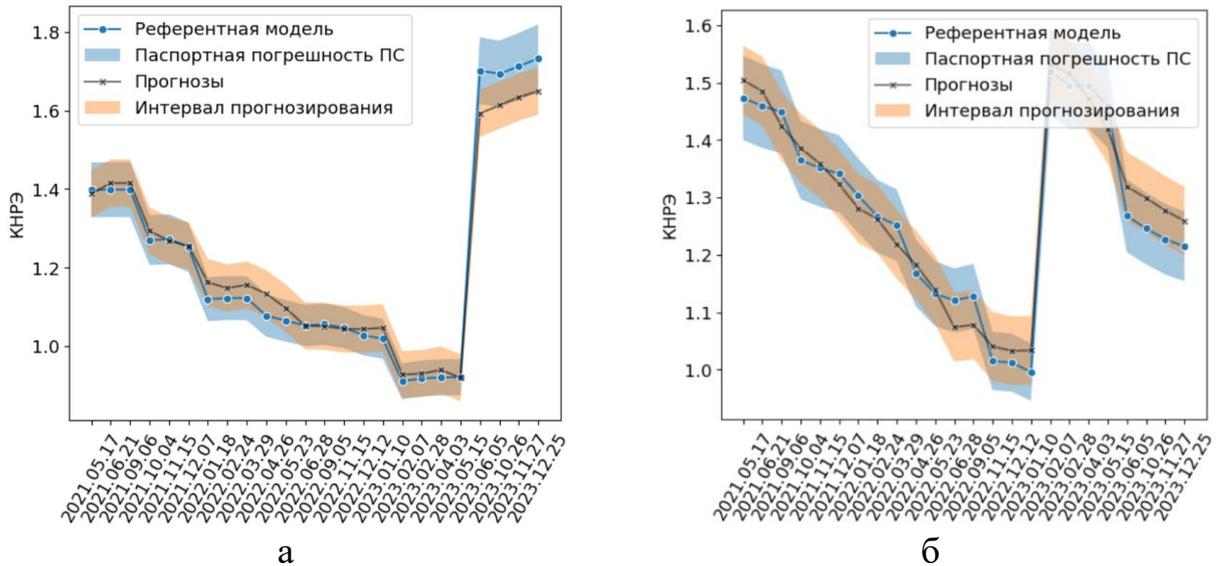


Рисунок 3.39 – Сопоставление прогнозных и расчетных (эталонных) значений КНРЭ: а – ячейка 5В; б – ячейка 5Е

Из распределений рисунка 3.39 следует, что характер изменения прогнозных значений согласуется с референтным и удовлетворяет допустимый предел погрешности. Средняя сходимость значений в ячейках по критерию R^2 составила 0,94, при САО 0,036.

Отклонения прогнозных значений от аттестованной модели и экспериментальных данных обусловлены ошибкой моделирования НФХ искусственных нагрузок, небольшим размером обучающей выборки, ошибкой интерполяции «новых» положений РО, а также частичным учетом процессов «отравления» и «разотравления» бериллия (рисунок 3.3). Суммарная накопленная ошибка может быть описана согласно (3.26).

$$\delta = \sqrt{\delta_{Be}^2 + \delta_{MCU}^2 + \delta_M^2} \quad (3.26)$$

где,

δ_{Be} – ошибка за счет усреднения концентраций «отравителей» в бериллии;

δ_{MCU} – ошибка моделирования НФХ;

δ_M – ошибка прогнозной модели.

Уменьшение вклада компонент (3.26) позволит повысить точность прогнозируемых значений. Тем не менее, проведенный верификационный анализ и кросс-валидация на основе эталонных расчетов и экспериментальных данных показали устойчивость и стабильность предсказаний, что обуславливает

возможность применения разработанных моделей для определения значений КНРЭ и размножающих свойств активной зоны реактора ИРТ-Т для эксплуатационных загрузок.

Исходя из того, что при формировании прогнозов на основе интерполяции «новых» положений РО стабильность прогнозов не нарушается, дополнительно была рассмотрена возможность прямой валидации предсказаний и расширения области применения модели. Подход базируется на сравнении прогнозных и экспериментальных кривых эффективности групп КО1 и КО2, которые характеризуют компенсацию и высвобождение избыточной реактивности (запаса реактивности) в процессе топливной кампании. Для построения кривых эффективности групп КО1 и КО2 с помощью прогнозной модели достаточно рассмотреть фиксированную компоновку с набором положений РО СУЗ и осуществить расчет физического «веса» согласно:

$$\rho = \int_0^H \frac{d\rho}{dh} dh \quad (3.27)$$

где,

H – полная высота погружения РО, см;

Экспериментальные значения физического «веса» групп КО1 и КО2 определялись исходя из динамики перемещения стержней в процессе нестационарного «отравления» ксеноном-135 за первые 12 часов работы реактора на мощности, чтобы исключить влияние выгорания топлива (рисунок 3.40а). Для восстановления всей интегральной кривой была обработана одна из кампаний реактора за 2023 г. На рисунке 3.40б приведены интегральные характеристики групп КО1 и КО2 полученные на основе обработки экспериментальных данных и серии прогнозов модели при разном положении РО.

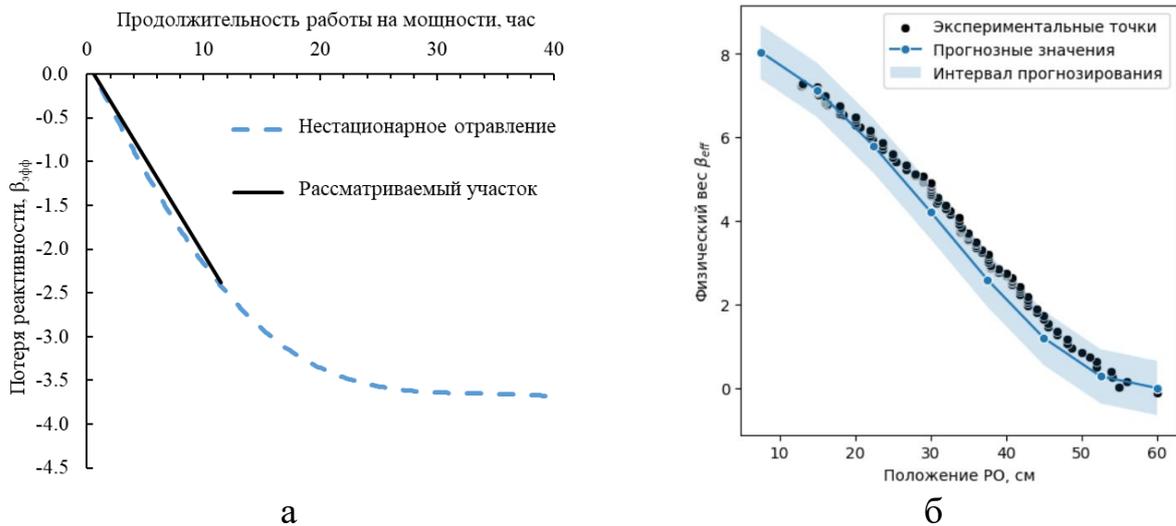


Рисунок 3.40 – Определение эффективности групп КО1 и КО2:

а – учет скомпенсированной реактивности за счет «отравления» ксеноном-135;

б – сопоставление экспериментальных значений с прогнозной моделью

Как можно видеть, экспериментальные и прогнозные значения хорошо согласуются между собой по всей высоте поглощающих стержней. Общая точность определения кривой эффективности групп КО1 и КО2 составила $R^2 = 0,95$. Это позволяет судить о возможности использования модели для расчетного определения эффективности групп КО1, КО2 и изменения запаса реактивности реактора.

Таким образом, по результатам проведенных тестов и сравнений необходимо отметить, что:

- разработанные модели могут рассматриваться как объясняемые – формируемые прогнозы интерпретируемы, имеют согласованность со статистическими распределениями и установленными обобщенными закономерностями;

- прогнозы устойчивы к «шумам», модели способны учитывать изменения выходных значений при незначительной вариации входных параметров, что позволяет оценивать значения КНРЭ и запаса реактивности в рамках реальных топливных циклов;

- прогнозы КНРЭ и запаса реактивности имеют сходимость с эталонными результатами моделирования и экспериментальными данными, что позволяет

судить о применимости моделей для оценки эксплуатационных характеристик реактора ИРТ-Т;

3.4 Результаты и выводы по главе 3

По результатам исследований, представленных в настоящей главе, можно сделать следующие выводы:

- для определения распределений энерговыделения и запаса реактивности предложено использовать инструменты ИИ, которые позволяют прогнозировать значения, исходя из статистических связей в данных с высокой размерностью или многомерными зависимостями. Предложено провести статистических анализ данных для установления обобщенных закономерностей и формирования оптимальной стратегии обучения, тестирования, а также интерпретации результатов;

- разработана гауссовская модель генерации топливных загрузок на основе реконструкции состава топлива для формирования набора данных, описывающего реальные состояния активной зоны реактора ИРТ-Т. Это позволило подготовить обучающую и тестовую выборки, содержащие разнообразные комбинации ТВС и учитывающие регламентное перемещение групп РО КО1, КО2 и КО3;

- по результатам статистического анализа, включающего описательную статистику, статистический вывод и корреляционный анализ, установлены особенности распределения значений энергонапряженности и запаса реактивности в активной зоне реактора ИРТ-Т. На основе полуэмпирических зависимостей описаны закономерности формирования энерговыделения и запаса реактивности в зависимости от степени выгорания топлива, ячейки, комбинаций ТВС и положений РО;

- проведена оценка прогнозных возможностей алгоритмов машинного обучения и сформирован подход к использованию ансамблей моделей на основе метода градиентного бустинга и L2-регуляризации. Разработанные ИИ-модели позволяет прогнозировать значения КНРЭ и запаса реактивности на тестовых

массивах с САО 0,014 и 0,33 $\beta_{эфф}$, а также с общей точность $R^2 = 0,98$ и $R^2 = 0,97$, соответственно;

– для определения максимально напряженных участков в твэлах разработан комбинированный подход, основанный на адаптации распределений упрощенной геометрии для прогнозов в детальной. Для этого было предложено использовать нейросетевую архитектуру в многозадачном обучении, что позволило на основе 48 примеров ($\approx 2\%$ от размера всей выборки упрощенной геометрии) разработать модель MLP_MTL + Residual-блок с общей сходимостью $R^2=0,93$, при САО 0,037;

– верификация прогнозных моделей проводилась на основе SHAR-значений и установленных обобщенных зависимостей формирования значений КНРЭ и запаса реактивности, что позволило установить интерпретируемость моделей, устойчивость к «шумам» и объяснимость прогнозов;

– валидация ИИ-моделей базировалась на сопоставлении с эталонными расчетами и экспериментальными данными реактора ИРТ-Т за 2021-2023 гг. Сходимость с экспериментальным запасом реактивности активной зоны составила $R^2 = 0,94$, при САО 0,39 $\beta_{эфф}$. Погрешность прогнозов экспериментальной критичности не превышает 0,51 $\beta_{эфф}$, что удовлетворяет максимальной погрешности аттестованной модели $\pm 2,5 \beta_{эфф}$. Сходимость прогнозов и референтных расчетов относительно значений КНРЭ составила $R^2 = 0,94$, при САО 0,036, что удовлетворяет паспортной погрешности определения энерговыделения.

Глава 4. Алгоритмизированный поиск оптимальных топливных загрузок активной зоны реактора ИРТ-Т

Результаты исследования, представленные в предыдущей главе, показали, что методы машинного и глубокого обучения позволяют определять размножающие свойства активной зоны с общей точностью $R^2 \approx 0,97$, перераспределение энерговыделения и значения КНРЭ с точностью $R^2 \approx 0,98$ и $R^2 \approx 0,93$ для упрощенной геометрии и детальной геометрии, соответственно.

Несмотря на то, что прогнозные модели применимы для любых топливных конфигураций, это не позволяет решить проблему выбора ТВС для перестановок при профилировании активной зоны реактора ИРТ-Т. Формирование типовых схем и операций в явном виде не представляется возможным, так как в результате большого разнообразия возможных комбинаций ТВС в активной зоне одни и те же действия будут давать разный результат.

Оптимальным решением могла бы быть реализация итерационного перебора всех возможных комбинаций и выбор наиболее подходящего результата на основе установленных критериев. Однако для активной зоны реактора ИРТ-Т, содержащей 20 топливных ячеек, количество возможных комбинаций ТВС только для одной загрузки составляет $20! \approx 2,4 \cdot 10^{18}$, что является NP-трудной задачей. При решении таких задач могут быть использованы, как точные методы, когда требуется гарантированно оптимальное решение, так и метаэвристика для поиска приближенного решения. Но при использовании точных методов существует проблема экспоненциального роста времени вычислений, которая при количестве задач $N > 10$ уже существенна.

Методы метаэвристики позволяют достичь баланса между точностью и скоростью, что может быть адаптировано для поиска оптимальной загрузки активной зоны реактора ИРТ-Т.

4.1 Формализация процесса направленного случайного поиска

4.1.1 Условия оптимизационного поиска и выбор алгоритма

Среди методов метаэвристики наиболее эффективными являются:

- эволюционные алгоритмы: генетический алгоритм, дифференциальная эволюция и др.;
- алгоритмы коллективного поведения: рой частиц, муравьиная колония и др.;
- физико-инспирированные: имитация отжига, гармонический поиск.

В зависимости от типа данных, размерности, количества оптимизационных целей и проблем локального и глобального экстремума, эффективность того или иного алгоритма будет существенно отличаться.

Для выбора подходящего алгоритма необходимо сформировать основные критерии «оптимальной» топливной загрузки активной зоны, способы её количественной оценки, а также основные ограничения «системы» относительно которых будет осуществляться поиск. На основе опыта проведения расчетно-экспериментальных работ были сформулированы условия, которые необходимо учитывать:

- при проведении перегрузочных работ формирование топливной загрузки осуществляется исходя из принципа максимизации запаса реактивности, который обуславливает длительность топливной кампании. Также учитываются неравномерность распределения энерговыделения по ячейкам и значения ОКНРЭ, которые характеризуют эффективность использования топлива и отражают тепловые режимы работы наиболее напряженных топливных элементов;
- формирование «оптимальной» компоновки осуществляется только для рассматриваемого набора ТВС посредством перестановок, то есть рассматриваются фиксированные вектора выгорания $\mathbf{V} = [B_1, \dots, B_{FA}]$ и позиций ТВС $\mathbf{X} = [x_1, \dots, x_{FA}]$, где $FA=20$;
- количество ТВС в активной зоне фиксировано, изменение назначения ячеек не допускается (например, замена топлива на отражатель);

– РО СУЗ установлены в шеститрубных ТВС, их расположение неизменно;

– допускаются перестановки между шеститрубными ТВС, но с учетом размещения РО СУЗ в фиксированных ячейках. Однако на практике такие осуществляются крайне редко ввиду практической сложности и продолжительности процедуры.

Следовательно, алгоритм должен осуществлять адаптивный поиск в пространстве с дискретными переменными (ячейки с ТВС) для фиксированного набора ТВС (картограмма выгорания), исходя из запаса реактивности (макропараметра) и неравномерности распределения энерговыделения в ячейках (микропараметров), при большом количестве примеров с возможными локальными экстремумами.

Для учета всех упомянутых особенностей поиска оптимальной топливной загрузки, предлагается разработать метод адаптивного поиска на основе генетического алгоритма (ГА), который применим к дискретным данным, устойчив к локальным экстремумам и позволяет исследовать удаленные области пространства решений за счет операторов модификаций.

ГА – популяционный алгоритм, элементом популяции является генотип, который хранит информацию необходимую для полного описания состояния объекта. Направленный случайный поиск в ГА реализуется с помощью механик модификации генотипа, аналогичных естественному отбору в природе, среди которых: отбор, скрещивание (комбинация), мутация и элитизм [126–128].

Количественная оценка работы алгоритма, в общем случае, осуществляется на основе функции приспособленности, которая определяет рейтинг каждого генотипа и популяции в целом, на основе целевых параметров (функций):

$$F(x) = [f_1(x), \dots, f_N(x)], \quad (4.1)$$

$$D_x \subset \{x\} = R^{|x|},$$

где,

$f(x)$ – целевая функция;

N – количество критериев (целевых функций);

D_x – множество параметров;

R – пространство параметров.

При $N > 1$ задача представляет собой многокритериальную оптимизацию (МКО), которая ориентирована на минимизацию или максимизацию функции приспособленности. Допускаются различные способы решения задачи МКО [129; 130], одной из которых является использование весовых характеристик:

$$F(x) = \sum_i^N f_i(x)\omega_i, \quad (4.2)$$

где,

ω – весовой признак целевой функции.

Математический вид целевых функция уникален для каждой задачи и параметра, поэтому формируется на основе критериев оптимизационного поиска.

В процессе оптимизационного поиска размер популяции не изменяется за счет отбора решений с наибольшим значением рейтинга приспособленности и исключения с наименьшим. Поэтому каждая новая итерация имеет более высокий средний рейтинг, чем предыдущая, что обуславливает процесс «эволюции» и формирования более оптимальных решений за счет случайного поиска.

4.1.2 Разработка модификационных операторов и процедуры оптимизации

В качестве данных для кодирования и представления в генотипе предлагается рассмотреть следующие параметры активной зоны с привязкой к позициям ячеек $\mathbf{X} = [x_1, \dots, x_{FA}]$:

- глубина выгорания топлива $\mathbf{B} = [B_1, \dots, B_{FA}]$;
- КНРЭ $\mathbf{K}_\ominus = [K_1, \dots, K_{FA}]$;
- запас реактивности реактора ρ .

Количество генов (параметров), описывающих генотип составляет 41. При этом важно отметить, что к «изменяемым» генам можно отнести только значения глубины выгорания, модификация которых отражает перестановочные действия в активной зоне. Значения энерговыделения и запаса реактивности могут быть получены только для модифицированной компоновки на основе моделирования

или прогнозной модели. Схематично процесс модификации генотипа может быть описан как:

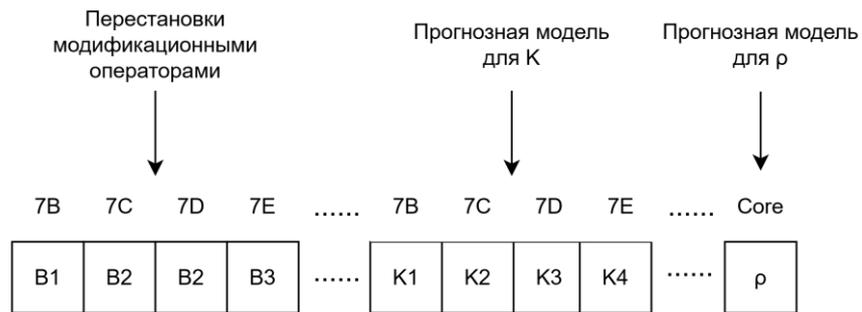


Рисунок 4.1 – Процедура модификации генотипа

Фактически это сводит процедуру модификации к двум последовательным этапам: формирование картограммы за счет перестановок ТВС и прогнозы значений КНРЭ и запаса реактивности. Это позволит учесть все необходимые характеристики активной зоны и провести количественное определение целевых функций и функции приспособленности [131].

Сравнительный анализ значений КНРЭ при упрощенной и детальной геометрии ТВС показал, что существенный рост энерговыделения наблюдается в центральных ячейках с ТВС, выгорание которых не более 15 % (таблица 3.5). Поэтому в зависимости от поставленной задачи возможно использовать как модель GBR + L2 для общей оценки КНРЭ, так и ИНС MLP_MTL + Residual-блок для оценки наиболее напряженных участков.

Формирование новых решений посредством случайного изменения топливной загрузки осуществляется с помощью операторов скрещивания и мутации. Принцип работы оператора скрещивания базируется на случайном выборе ячеек от двух исходных генотипов для составления нового (рисунок 4.2).

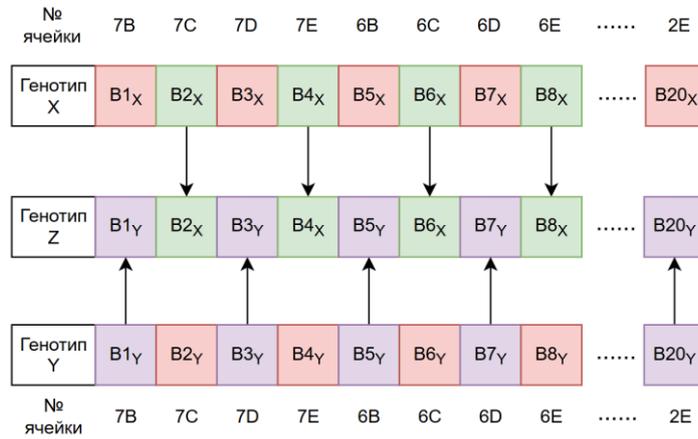


Рисунок 4.2 – Модификационный оператор скрещивания

Исключение дубликатов в выходном генотипе достигается за счет алгоритма маркировки ячеек, при котором выбор уже использованных ТВС не допускается. «Качество» генотипов играет важную роль в процессе оптимизации, так как при выборе «хорошего» и «плохого» родительских генотипов будет наблюдаться снижение общего рейтинга решений, что может привести к ухудшению результатов или вывести процедуру поиска на стадию «насыщения». Для регуляризации этого процесса в модификаторе скрещивания предлагается использовать алгоритм приоритизации, который регулирует выбор количества генов от каждого родителя:

$$Ch^Z = (1 - \gamma) \cdot Ch^X + \gamma \cdot Ch^Y,$$

$$\gamma = 0.5, \frac{F(Ch^X) - F(Ch^Y)}{F(Ch^X)} \in [0.95; 1.05],$$

$$\gamma = 0.2, \text{ otherwise}$$
(4.3)

где,

Ch^X, Ch^Y – входные (родительские) генотипы;

Ch^Z – выходной генотип;

γ – взвешивающий коэффициент;

Используется взвешивающий коэффициент γ , величина которого зависит от степени «близости» родительских генотипов по рейтингу. Если они отличаются на величину не более 5%, то при скрещивании используется равное количество генов от каждого, в случае большей разницы, количество генов распределяется в соотношении 1:4 в пользу генотипа, обладающего большей приспособленностью.

Это позволит поддерживать разнообразие решений при повышении их общего рейтинга.

Оператор мутации используется как функция поддержания стохастичности генерируемых решений и берет за основу только один генотип, в котором случайным образом некоторые гены меняются местами (рисунок 4.3)

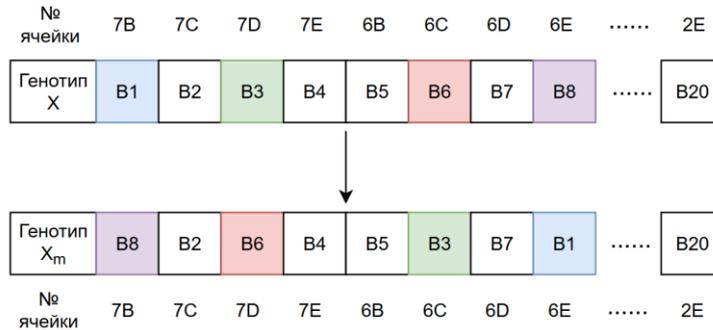


Рисунок 4.3 – Модификационный оператор мутации

Чтобы предотвратить внесение решений с низким рейтингом приспособленности на заключительных этапах поиска, оператор мутации задается в виде степенной функции с отрицательным показателем:

$$P_m^i = P_m^0 \cdot k^{-i}, \quad (4.4)$$

где,

P_m^0 – стартовая вероятность мутации;

k – целое число, влияющее на скорость уменьшения вероятности;

i – номер итерации.

Для общей популяции, сформированной на основе скрещивания и мутации, проводится отбор решений с применением концепции элитизма, при которой доля наилучших решений автоматически проходит в следующую итерацию. Критерии отбора включают как оценку рейтинга решений, так и вероятность случайного выбора.

Таким образом, оптимизационный поиск топливных загрузок на основе модификационных операторов и прогнозных моделей, предлагается проводить по общей схеме:

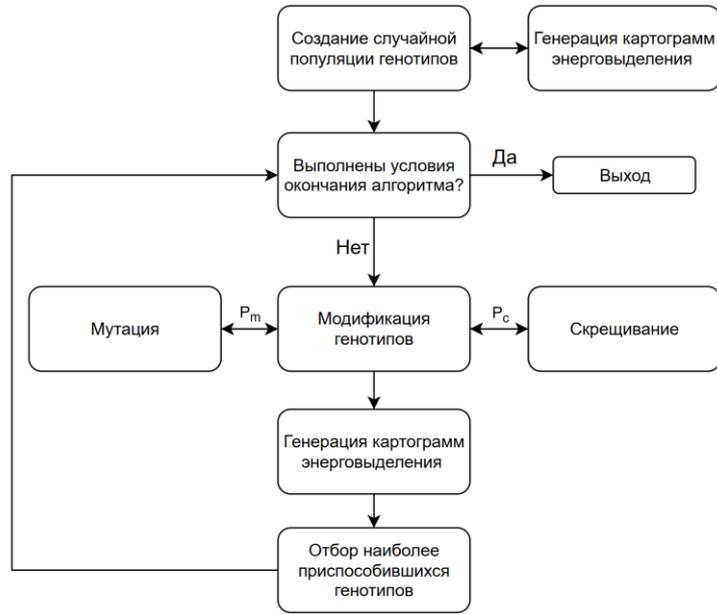


Рисунок 4.4 – Схема работы ГА: P_c – вероятность скрещивания

Вероятности мутации и скрещивания определяются эмпирически, так как оказывают существенную роль на рейтинг популяции и отдельных генотипов.

4.2 Определение параметров поиска топливных компоновок

Для формирования рейтинга решений предлагается рассмотреть целевые функции запаса реактивности и ОКНРЭ, которые сводятся к однокритериальному типу оптимизации за счет взвешенной линейной комбинации (4.2). В рамках задачи принимается, что рейтинг решения тем выше, чем больше запас реактивности активной зоны ρ и меньше ОКНРЭ K_V . Увеличение ρ сопровождается ростом K_V , поэтому для формирования топливных загрузок, характеризующихся длительными циклами и небольшими значениями КНРЭ, требуется соблюдение баланса между целевыми параметрами.

Начальную количественную оценку коэффициента приспособленности с целевыми функциями запаса реактивности и ОКНРЭ предлагается проводить согласно оригинальной функции:

$$F(x)^{i,j} = (1 - \omega) \cdot k_{\rho}^{i,j} + \omega \cdot k_{K_V}^{i,j},$$

$$F(x)^{i,j} = (1 - \omega) \cdot \exp(-m_{\rho}(\rho^{\max} - \rho^{i,j})) + \omega \cdot \exp(-m_{K_V}(K_V^{\max} - K_V^{i,j})),$$
(4.5)

где,

i, j – номер итерации и генотипа популяции;

m_ρ – коэффициент масштаба функции запаса реактивности;

m_{K_V} – коэффициент масштаба функции ОКНРЭ;

ρ^{\max}, K_V^{\max} – предельные (целевые) значения запаса реактивности и ОКНРЭ.

Как правило, значения целевых функций формируется относительно предельных значений, принятых как глобальный максимум, что влияет на их количественную оценку в зависимости от исходной топливной картограммы. В настоящей работе предлагается использовать локальные предельные значения, которые динамически изменяются в процессе адаптивного поиска. Это позволит учитывать особенности каждой картограмм относительно максимально возможных значений ρ и K_V .

Предложен экспоненциальный вид целевых функций с коэффициентами масштаба, чтобы обеспечить высокую чувствительности алгоритма к изменениям. Значения целевых функций нормированы и изменяются в диапазоне от 0 до 1, поэтому варьирование масштабных коэффициентов не ограничивает общую процедуру поиска. На рисунке 4.5 приведен общий характер изменения целевых функций запаса реактивности и ОКНРЭ при разных коэффициентах масштаба.

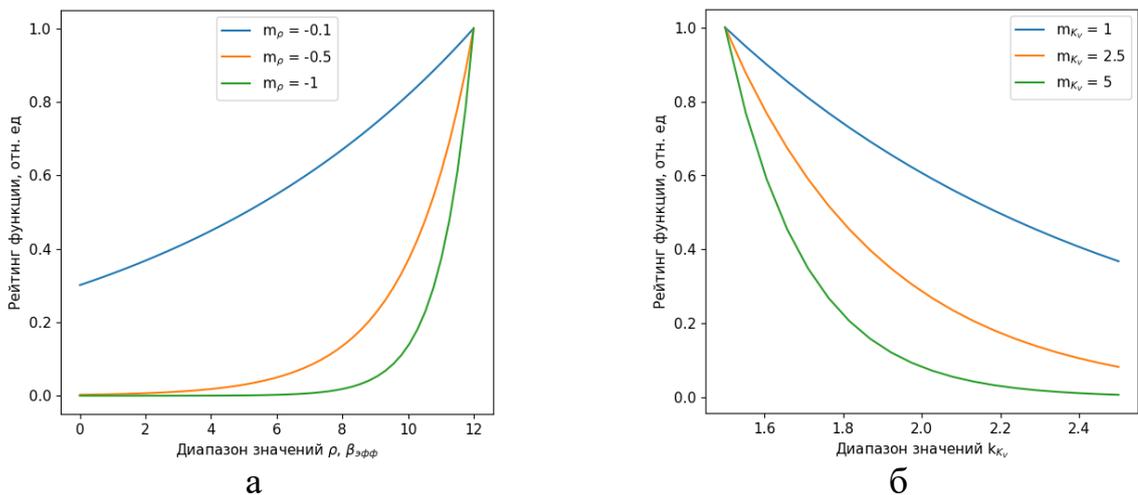


Рисунок 4.5 – Масштабирование целевых функций: а – функция запаса реактивности; б – функция ОКНРЭ

Процесс поиска решений в ГА может регулироваться следующими гиперпараметрами:

- размер популяции, влияющий на количество формируемых и анализируемых решений за итерацию. Как правило, выбирается по эмпирическому правилу $Pop \approx 10 \cdot \sqrt{FAs} \approx 50$;
- вероятности мутаций $P_m=0,1$ и скрещивания $P_c=0,5$ для внесения новых $Pop_{new} = 50 \cdot 0,1 + 50 \cdot 0,5 = 30$ генотипов за одну итерацию, что составляет 60 % от исходной популяции (далее незначительное уменьшение за счет снижения P_m);
- весовые коэффициенты целевых функций ω_p и ω_{kv} ;

4.2.1 Определение параметров функции приспособленности

Подбор гиперпараметров предлагается проводить последовательно и опираясь на результаты работы алгоритма: определение весовых коэффициентов для выбора оптимального направления поиска решений; варьирование вероятностей модификационных операторов и размера популяции при недостижимости желаемого результата или ограниченности поиска ввиду популяционного «насыщения».

Общая оценка функции приспособленности и тестировании предложенной схемы работы ГА проводилась на основе модельной (искусственной) топливной компоновки (таблица 4.1). Ключевая задача этого этапа – определение оптимизационных возможностей алгоритма с учетом локальных и глобальных экстремумов функции (4.5).

Таблица 4.1 – Модельная загрузка активной зоны для тестирования механизмов ГА

	Глубина выгорания, %				КНРЭ			
	В	С	D	Е	В	С	D	Е
7	45,69	53,75	48,84	37,51	0,87	0,88	1,02	1,25
6	48,92	47,28	34,38	52,48	0,86	1,15	1,49	1,06
5	53,69			47,59	1,03			1,56
4	38,74			23,35	1,39			2,14
3	32,55	26,24	29,9	36,89	1,32	1,73	1,73	1,57
2	46,12	52,52	20,91	33,98	1,16	1,18	1,77	1,61

$$\rho = 6,38\beta_{эфф}$$

$$K_V = 2,14$$

Как можно видеть, ТВС размещены в ячейках случайным образом. В зависимости от поставленной задачи, возможно перемещение наиболее «свежих» ТВС в правую сторону активной зоны, что позволит повысить запас реактивности, однако это приведет к локальному «всплеску» энергонапряженности. Эмпирическое варьирование весовых коэффициентов функции приспособленности позволит оценить в каком случае достигается оптимальный баланс между целевыми функциями.

С целью приближения работы ГА к реальному процессу профилирования, перестановки шеститрубных ТВС с РО СУЗ не рассматриваются, то есть допускаются перестановки 12-ти ТВС. На рисунке 4.6 представлены изменения функции приспособленности при разных значениях весовых коэффициентах целевых функций.

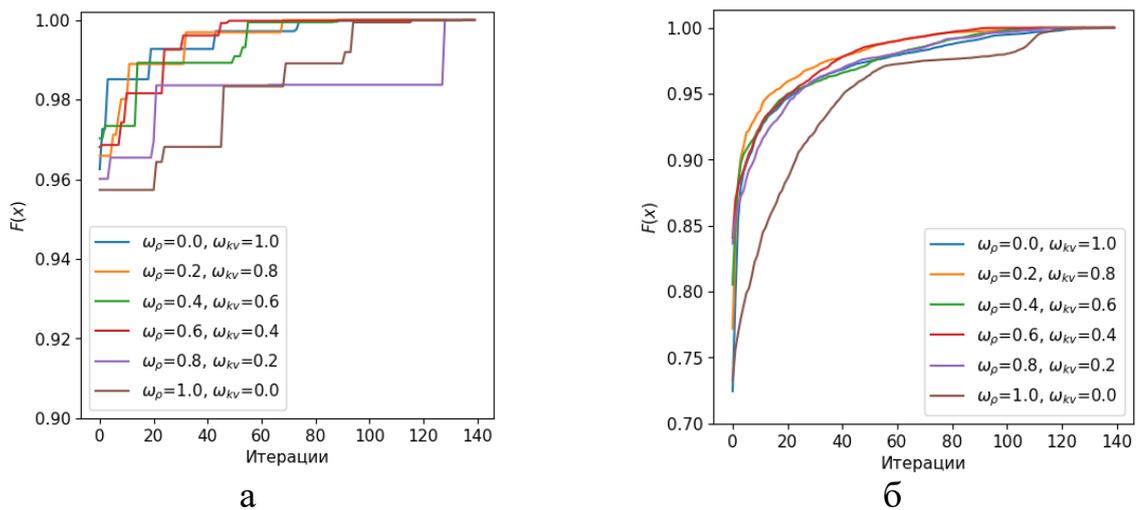


Рисунок 4.6 – Процесс поиска оптимальной топливной загрузки при разных весовых коэффициентах целевых функций: а – рейтинг наилучшего решения; б - рейтинг популяции

Из рисунка 4.6 видно, что комбинация взвешивающих коэффициентов существенно не влияет на итерационную сходимость алгоритма. Для нахождения оптимального решения количество генерируемых и анализируемых вариантов составляет 8 – 12 тысяч, что характеризует адаптивное уменьшение размерности пространства решений (существует $12! \approx 479 \cdot 10^6$ комбинаций) и обуславливает возможность формирования компоновок, удовлетворяющих заданным критериям. Среднее время, затрачиваемое на поиск решения, составляет 60–120 секунд.

Представленные зависимости функций приспособленности нормированы на максимальное значение, динамика изменения различна в зависимости от заданных весовых коэффициентов. Это свидетельствует о разном количественном вкладе целевых функций и обусловлено отличиями в протекании физических процессов: рост запаса реактивности пропорционален росту ОКНРЭ, но присутствует вклад «гетерогенности» ячеек и комбинаций ТВС. В таблице 4.2 приведены наилучшие решения, сформированные ГА при разных весовых коэффициентах.

Таблица 4.2 – Оптимальные загрузки в зависимости от весовых коэффициентов

		Весовые коэффициенты: $\omega_p=0,0$, $\omega_{kv}=1,0$							
		Глубина выгорания, %				КНРЭ			
		В	С	D	Е	В	С	D	Е
7		46,12	33,98	20,91	37,51	1,03	1,33	1,60	1,40
6		48,92	47,28	34,38	52,48	0,98	1,27	1,62	1,15
5		53,69			47,59	1,10			1,56
4		52,52			53,75	1,14			1,40
3		32,55	26,24	29,90	36,89	1,26	1,58	1,59	1,41
2		45,69	23,35	48,84	38,74	1,08	1,49	1,16	1,33
		$\rho = 5,21 \beta_{эфф}$							
		$K_V=1,62$							
		Весовые коэффициенты: $\omega_p=1,0$, $\omega_{kv}=0,0$							
		Глубина выгорания, %				КНРЭ			
		В	С	D	Е	В	С	D	Е
7		47,59	48,84	38,74	33,98	0,93	1,04	1,30	1,48
6		48,92	47,28	34,38	52,48	0,91	1,23	1,62	1,17
5		53,69			23,35	1,06			2,15
4		37,51			20,91	1,33			2,17
3		32,55	26,24	29,90	36,89	1,19	1,57	1,62	1,47
2		53,75	52,52	46,12	45,69	0,91	1,03	1,22	1,27
		$\rho = 6,85 \beta_{эфф}$							
		$K_V=2,17$							
		Весовые коэффициенты: $\omega_p=0,4$, $\omega_{kv}=0,6$							
		Глубина выгорания, %				КНРЭ			
		В	С	D	Е	В	С	D	Е
7		37,51	48,84	33,98	23,35	1,15	1,12	1,42	1,65
6		48,92	47,28	34,38	52,48	0,99	1,29	1,65	1,15
5		53,69			45,69	1,12			1,64
4		20,91			38,74	1,64			1,70
3		32,55	26,24	29,90	36,89	1,22	1,56	1,56	1,39
2		53,75	46,12	47,59	52,52	0,94	1,12	1,15	1,08
		$\rho = 5,98 \beta_{эфф}$							
		$K_V=1,70$							

Сравнивая полученные компоновки с исходной картограммой можно отметить, что все решения имеют принципиальные отличия относительно параметров K_V и ρ :

- при большом значении весового коэффициента целевой функции ОКНРЭ ($\omega_{KV}=1,0$) алгоритм размещает наиболее свежие ТВС на периферии (ячейки 7D, 2E), чтобы снизить их энергонапряженность и достичь наименьшего значения $K_V = 1,62$, при $\rho = 5,21 \beta_{эфф}$;

- при большом весовом коэффициенте целевой функции запаса реактивности ($\omega_\rho = 1,0$) алгоритм размещает «свежие» ТВС в наиболее энергонапряженных ячейках (ячейки 5E и 4E), что приводит к существенному росту $K_V = 2,17$, но позволяет достичь максимального значения $\rho = 6,85 \beta_{эфф}$;

- наиболее оптимальная топливная загрузка, с точки зрения баланса параметров K_V и ρ , достигается при значениях весовых коэффициентов $\omega_\rho = 0,4$ и $\omega_{KV} = 0,6$. В этом случае достигаются значения характеристик $K_V = 1,70$ и $\rho = 5,98 \beta_{эфф}$;

В процессе формирования топливной загрузки алгоритм определяет оптимальные ячейки с ТВС исходя из значений целевых функций, что позволяет анализировать множество вариантов и находить те, которые удовлетворяют критериям. Для рассмотренных циклов правила размещения ТВС в ячейках не предусматривались, что обусловило формирование оптимальных (по характеристикам) загрузок, но со случайными комбинациями ТВС.

При перегрузочных работах на реакторе ИРТ-Т в большинстве случаев устанавливаются 2 «свежие» ТВС, поэтому для картограмм загрузок характерны пары ТВС с близкими значениями глубины выгорания. Следовательно, использование предложенных топливных загрузок в исходном виде затруднительно, так как потребуются большое количество оперативных (перестановочных) действий для формирования компоновки, приближенной к реальной.

4.2.2 Регуляризация решений на основе симметрии топливных ячеек

Процедуру поиска возможно скорректировать за счет добавления экспертных логических правил, ограничивающих количество перестановок или проводящих анализ ТВС с близкими значениями выгорания и т.д., но это сводит оптимизационный поиск к виду «если-то», что может ограничить возможности подхода.

Ранее было отмечено, что активная зона реактора ИРТ-Т не обладает свойствами геометрической симметрии, поэтому в рамках оптимизационного поиска рассматриваются все топливные ячейки, а не отдельный сектор. Для корректировки процедуры поиска относительно ячеек и ТВС, предлагается использовать критерии «условной» симметрии (рисунок 4.7). Это позволит регуляризовать перестановки близких по значению ТВС, рассматривая их как пары k_c , а также учитывать вклад несимметричного бериллиевого отражателя за счет коэффициентов симметрии четвертей k_q и сторон k_s .

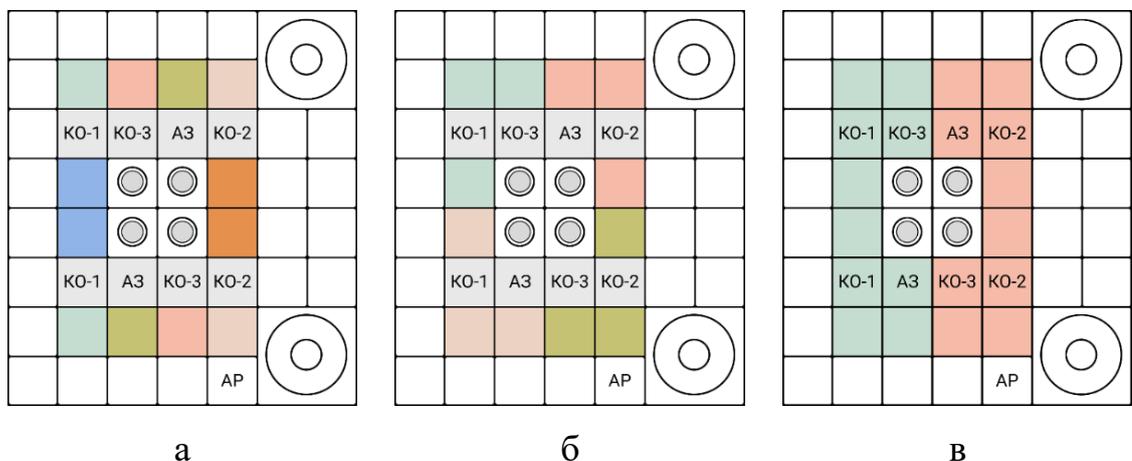


Рисунок 4.7 – Представление «условно» симметричных ячеек для регуляризации процедуры оптимизационного поиска: а – симметрия пар ячеек k_c ; б – симметрия четвертей k_q ; в – симметрия сторон k_s

Критерии «условной» симметрии распространяются как на значения глубины выгорания, так и на КНРЭ. Математическая формализация целевых функций регуляризации оптимизационного поиска представлены в виде (4.6) и (4.7).

$$k_c = \frac{\sum_{i=k,j}^n \frac{K^k}{K^j} + \sum_{i=k,j}^n \frac{B^k}{B^j}}{n}, \quad (4.6)$$

где,

n – количество парных ячеек;

k, j – пары ячеек;

K – значение КНРЭ в ячейке;

B – значение глубины выгорания в ячейке;

$$k_{q,s} = \frac{\sum_{i=1}^p \frac{\sum_{i=1}^m K^i}{m}}{p}, \quad (4.7)$$

где,

p – количество секторов;

m – количество ячеек в секторе;

С учетом введенных критериев «условной» симметрии функция приспособленности будет иметь вид:

$$F(x)^{i,j} = (1 - \alpha) \cdot \left[(1 - \omega) \cdot k_{\rho}^{i,j} + \omega \cdot k_{K_v}^{i,j} \right] + \alpha \cdot (k_c^{i,j} + k_q^{i,j} + k_s^{i,j}), \quad (4.8)$$

где,

α – коэффициент регуляризации, $\alpha \in (0; 1,0]$

Проведенные эмпирические тесты показали, что оптимальная регуляризация за счет коэффициентов симметрии, без ухудшения качества решений относительно основных целевых функций, достигается при значениях $\alpha = 0,2-0,3$.

Далее проводился повторный поиск компоновки для исходной модельной картограммы на основе модифицированной функции приспособленности при значениях весовых коэффициентов целевых функций $\omega_{\rho} = 0,4$ и $\omega_{K_v} = 0,6$, значение коэффициента регуляризации принято равным $\alpha = 0,3$. Для наглядной демонстрации процесса случайного направленного поиска оптимальной загрузки в таблицу 4.3 вынесены примеры компоновок, формируемые на разных итерациях.

Таблица 4.3 – Формирование модельной топливной загрузки с учетом регуляризации

		Итерация 1 (Начало поиска)				Итерация 200 (Итоговое решение)			
		Глубина выгорания, %				КНРЭ			
		В	С	Д	Е	В	С	Д	Е
7		20,91	47,59	33,98	52,52	1,32	1,06	1,31	1,03
6		48,92	47,28	34,38	52,48	0,96	1,22	1,52	1,05
5		53,69			53,75	1,13			1,39
4		48,84			45,69	1,29			1,56
3		32,55	26,24	29,90	36,89	1,35	1,68	1,65	1,46
2		23,35	37,51	38,74	46,12	1,48	1,40	1,42	1,31
		$\rho = 4,94 \beta_{\text{эфф}}$							
		$K_V = 1,68$							
		Итерация 200 (Итоговое решение)				Итерация 200 (Итоговое решение)			
		Глубина выгорания, %				КНРЭ			
		В	С	Д	Е	В	С	Д	Е
7		48,84	33,98	37,51	23,35	1,03	1,62	1,36	1,52
6		48,92	47,28	34,38	52,48	0,84	1,12	1,44	1,04
5		53,69			46,12	0,95			1,62
4		53,75			45,69	1,06			1,64
3		32,55	26,24	29,90	36,89	1,15	1,53	1,53	1,37
2		52,52	38,74	47,59	20,91	1,34	1,41	1,80	1,47
		$\rho = 5,66 \beta_{\text{эфф}}$							
		$K_V = 1,80$							

Из примеров таблицы 4.3 видно, что на первых итерациях рейтинг решений небольшой, так как все картограммы получены на основе случайной генерации и незначительной модификации. В процессе работы алгоритма формируются решения, которые наиболее удовлетворяют критериям целевых функций с учетом регуляризации. В конечном итоге подбирается решение, для которого значения целевых функций максимальны, а в большинстве ячеек присутствуют «условно парные» ТВС с близкими значениями выгорания и энерговыделения. Сопоставляя итоговое ГА-решение с первоначальным вариантом (таблица 4.2), можно отметить, что осуществлен переход от «случайно размещенных» ТВС к компоновке с заданными (реальными) критериями.

4.3 Формирование оптимальных топливных компоновок активной зоны реактора ИРТ-Т

4.3.1 Тестирование на основе прошлых топливных циклов реактора

Далее осуществлялось тестирование разработанного алгоритма на основе реальных топливных загрузок. Сопоставление «прошлого» опыта профилирования компоновок с ГА-решениями позволит оценить эффективность метаэвристического алгоритма и «ручного» метода подбора загрузок. Тестирование ГА проводилось для топливных кампаний за период работы реактора ИРТ-Т в 2022-2023 гг.

Визуализация процесса направленного поиска оптимальной топливной загрузки реальной кампании №125 и сопоставление с «реальностью» представлено в таблице 4.4.

Таблица 4.4 – Тестирование ГА на основе топливной кампании реактора ИРТ-Т №125

		Итерация 200 (итоговое решение)				КНРЭ			
		Глубина выгорания, %				КНРЭ			
		В	С	Д	Е	В	С	Д	Е
7		58,57	0,00	26,60	21,86	0,77	1,71	1,47	1,64
6		20,86	47,87	10,17	17,81	1,29	1,14	1,90	1,81
5		49,17			38,49	1,04			1,66
4		57,85			36,91	0,86			1,59
3		20,50	9,00	47,47	16,85	1,18	1,50	1,11	1,60
2		58,55	25,92	0,00	29,32	0,68	1,18	1,55	1,28
		$\rho = 8,67 \beta_{эфф}$							
		$K_V=1,90$							
		Исходная компоновка (эмпирически сформированная)				КНРЭ			
		Глубина выгорания, %				КНРЭ			
		В	С	Д	Е	В	С	Д	Е
7		0,00	25,92	29,32	38,49	1,59	1,42	1,42	1,29
6		20,86	47,87	10,17	17,81	1,41	1,22	1,83	1,60
5		49,17			58,57	1,16			1,15
4		58,55			57,85	0,99			1,10
3		20,50	9,00	47,47	16,85	1,29	1,63	1,11	1,49
2		0,00	29,86	26,60	36,91	1,53	1,28	1,33	1,13
		$\rho = 6,87 \beta_{эфф}$							
		$K_V=1,83$							

Сопоставляя итоговое решение ГА с реальной компоновкой кампании №125, можно отметить, что ГА-решение имеет больший запас реактивности при незначительном увеличении значения ОКНРЭ (с 1,83 до 1,90). Сформированная компоновка соответствует критериям симметрии для большинства топливных ячеек.

Далее на основе сформированной компоновки моделировалась работа реактора на мощности и оценивалась длительность цикла без перегрузок. Расчетное моделирование показало, что предложенная загрузка на 18 % эффективнее – оценочное увеличение продолжительности цикла составило более 330 эффективных часов.

Аналогичным образом проводилась оптимизация других топливных загрузок активной зоны реактора ИРТ-Т с целью подтверждения стабильности и эффективности предложенного подхода. Результаты оптимизации топливных кампаний №124-127 приведены на рисунке 4.8 и в сводной таблице 4.5.

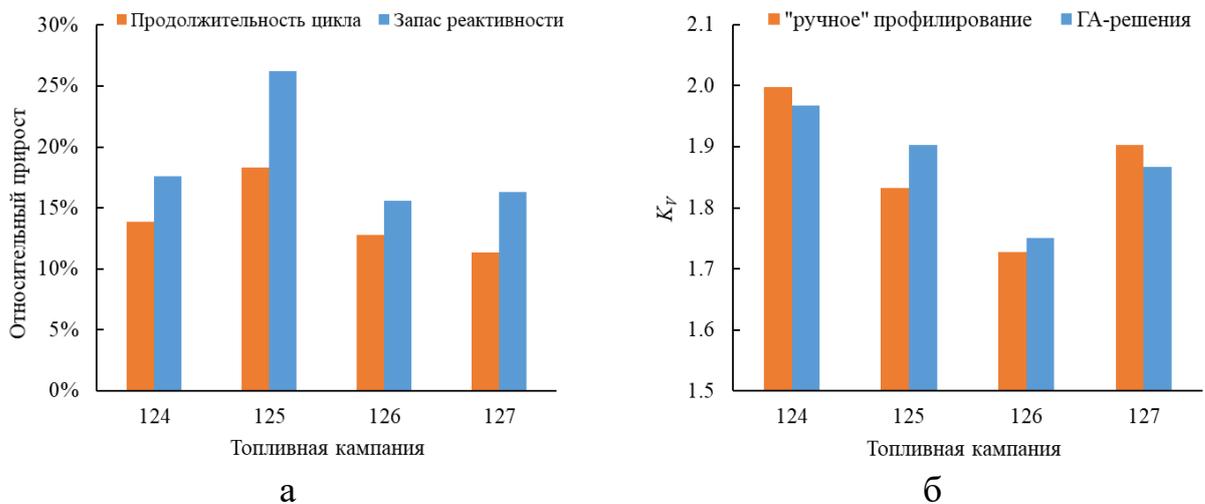


Рисунок 4.8 – Тестирование эффективности ГА-компоновок на основе «прошлых» загрузок зоны реактора ИРТ-Т: а – относительный прирост длительности кампании и запаса реактивности при использовании ГА; б – сравнение изменений ОКНРЭ

Таблица 4.5 – Сводные характеристики эксплуатационных загрузок и ГА-решений

№ кампании реактора	Эксплуатационные данные		ГА		Прирост длительности кампании, %
	$\rho, \beta_{эфф}$	K_V	$\rho, \beta_{эфф}$	K_V	
124	6,20	2,00	7,29	1,97	13,9
125	6,87	1,83	8,67	1,90	18,3
126	6,97	1,73	8,06	1,75	12,8
127	7,69	1,90	8,95	1,87	11,4

Из результатов таблицы 4.5 следует, что использование ГА для формирования топливных загрузок позволяет увеличить запас реактивности без существенного повышения значения K_V . Наблюдается прирост продолжительности для каждого топливного цикла и в среднем составил $\approx 14\%$, что свидетельствует о большей «оптимальности» ГА-компоновок и эффективности метода как с точки зрения выходного результата, так и ресурсов – не требуются затраты на подготовку, моделирование, обработку и анализ результатов.

4.3.1 Опытная эксплуатация ГА

Результаты тестирования ГА на «прошлых» топливных кампаниях реактора ИРТ-Т показали эффективность подхода. С целью дальнейшего тестирования возможностей алгоритма было разработано и утверждено техническое решение № 18.13/348-8 от 14.12.2023 о внедрении ГА с прогнозными моделями в опытную эксплуатацию для формирования топливных загрузок реактора ИРТ-Т. Опытная эксплуатация ГА реализовывалась совместно с аттестованной моделью ПС MSU-PTR согласно схеме рисунка 4.9.



Рисунок 4.9 – Блок-схема опытной эксплуатации ГА с прогнозными моделями

Из схемы рисунка 4.9 следует, что ГА является источников «генерации» новых компоновочных решений, прогнозирует значения КНРЭ и запаса реактивности, которые впоследствии подтверждаются на основе моделирования в аттестованной модели ПС MCU-PTR. Для оценки эффективности компоновочных решений, формируемых ГА, для каждой кампании дополнительно проводился «ручной» (экспертный) подбор загрузки.

За 2024 г на реакторе ИРТ-Т были проведены три перегрузочные работы, в основу которых легли компоновки, предложенные ГА. В таблицах 4.6-4.8 приведены ГА-загрузки и их характеристики, а также сравнение с картограммами, полученными «ручным» способом.

Таблица 4.6 – Формирование топливной загрузки кампании №128

	Глубина выгорания, %				КНРЭ			
	В	С	Д	Е	В	С	Д	Е
7	47,74	53,10	17,81	48,94	0,91	0,90	1,46	1,03
6	40,52	0,00	35,15	40,20	1,03	1,85	1,39	1,28
5	10,36			21,02	1,69			1,90
4	10,37			20,96	1,67			1,87
3	39,76	32,83	0,00	38,77	1,06	1,31	1,95	1,19
2	47,35	18,03	55,29	48,11	0,92	1,39	0,89	1,05

$\rho = 8,79 \beta_{\text{эфф}}$

$K_V = 1,90$

«Ручное» профилирование

	Глубина выгорания, %				КНРЭ			
	В	С	D	Е	В	С	D	Е
7	20,96	18,03	47,74	55,29	1,37	1,43	1,01	0,83
6	40,52	0,00	35,15	40,20	1,10	1,88	1,36	1,21
5	10,36			48,94	1,82			1,27
4	10,37			48,11	1,78			1,26
3	39,76	32,83	0,00	38,77	1,15	1,46	1,92	1,15
2	21,02	47,35	17,81	53,10	1,36	1,06	1,39	0,95

$\rho = 7,69 \beta_{эфф}$
 $K_V=1,92$

Можно видеть, что ГА-решение позволяет увеличить запаса реактивности активной зоны на $1,1 \beta_{эфф}$, при незначительном увеличении K_V с 1,92 до 1,95.

Таблица 4.7 – Формирование топливной загрузки кампании №129

	Глубина выгорания, %				КНРЭ			
	В	С	D	Е	В	С	D	Е
7	52,07	24,17	53,61	0,00	0,83	1,31	0,97	1,86
6	45,78	8,05	41,15	45,49	0,87	1,70	1,35	1,16
5	18,07			26,95	1,50			1,86
4	18,13			26,84	1,49			1,85
3	45,14	39,19	7,86	44,18	0,92	1,25	1,85	1,12
2	52,28	54,38	23,94	0,00	0,84	0,98	1,35	1,72

$\rho = 8,38 \beta_{эфф}$
 $K_V=1,86$

«Ручное» профилирование

	Глубина выгорания, %				КНРЭ			
	В	С	D	Е	В	С	D	Е
7	52,28	24,17	0,00	26,84	0,92	1,36	1,78	1,39
6	45,78	8,05	41,15	45,49	0,98	1,81	1,30	1,15
5	18,07			54,38	1,60			1,23
4	18,13			53,61	1,61			1,21
3	45,14	39,19	7,86	44,18	1,02	1,29	1,79	1,08
2	52,07	0,00	23,94	26,95	0,94	1,65	1,35	1,40

$\rho = 7,30 \beta_{эфф}$
 $K_V=1,79$

Найденное ГА-решение позволило увеличить запас реактивности активной зоны более чем на $1,1 \beta_{эфф}$.

Таблица 4.8 – Формирование топливной загрузки кампании №130

		ГА-решение				КНРЭ			
		Глубина выгорания, %							
		В	С	Д	Е	В	С	Д	Е
7		0,00	55,78	5,98	31,76	1,54	0,88	1,66	1,29
6		49,83	14,47	45,96	49,94	0,88	1,70	1,20	1,09
5		23,96			29,16	1,52			1,70
4		24,11			29,06	1,50			1,64
3		49,41	44,17	14,43	48,68	0,93	1,13	1,72	0,99
2		0,00	6,15	55,68	31,99	1,48	1,56	0,89	1,23

$$\rho = 8,76 \beta_{\text{эфф}}$$

$$K_V = 1,72$$

		«Ручное» профилирование				КНРЭ			
		Глубина выгорания, %							
		В	С	Д	Е	В	С	Д	Е
7		55,68	0,00	29,06	6,15	0,79	1,63	1,37	1,79
6		49,83	14,47	45,96	49,94	0,80	1,62	1,26	1,10
5		23,96			31,99	1,39			1,77
4		24,11			31,76	1,40			1,71
3		49,41	44,17	14,43	48,68	0,84	1,14	1,71	1,04
2		55,78	29,16	0,00	5,98	0,81	1,27	1,64	1,70

$$\rho = 7,95 \beta_{\text{эфф}}$$

$$K_V = 1,79$$

Компоновка кампании №130, сформированная ГА, имеет запас реактивности на $0,8 \beta_{\text{эфф}}$ больше, при меньшем значении ОКНРЭ.

Из представленных распределений таблиц 4.6 – 4.8 можно сделать вывод, что формируемые ГА-решения позволяют увеличить целевые эксплуатационные характеристики активной зоны реактора ИРТ-Т за счет размещения «свежих» ТВС таким образом, что «всплеск» их энергонапряженности компенсируется в удаленных ячейках. Например, в таблице 4.7 присутствует компенсация напряженности ячеек 2Е и 7Е за счет ячеек 4В и 5В.

Валидация предложенных компоновочных решений на основе аттестованной модели ПС MCU-PTR подтвердила отсутствие вылетов, стабильность формируемых прогнозов. По результатам моделирования циклов на основе сформированных конфигураций показано, что продолжительность ГА-компоновок выше более чем на 11 %. Сравнительные данные для каждой топливной кампании приведены на рисунке 4.10.

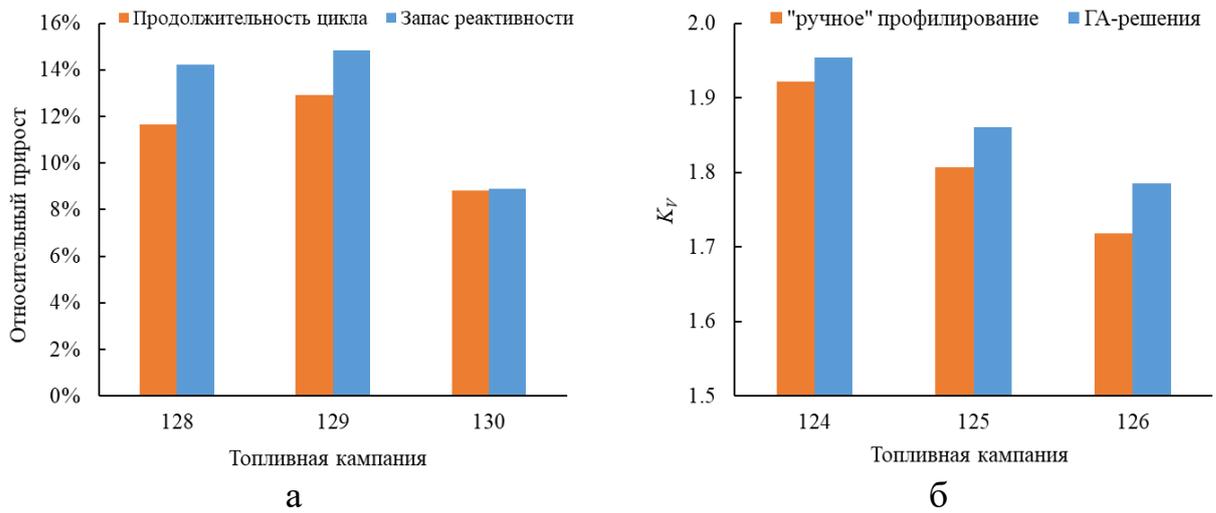


Рисунок 4.10 – Опытная эксплуатация ГА в 2024 г.: а – относительный прирост длительности кампании и запаса реактивности при использовании ГА; б – сравнение изменений ОКНРЭ

На основе компоновочных решений кампаний № 124-130 была проведена оценка изменения интенсивности (стабильности) нейтронного излучения в экспериментальных каналах реактора ИРТ-Т. Поиск по заданным критериям исключает решения, характеризующиеся существенными «всплесками» энерговыделения в топливных ячейках, что позволило снизить предельное изменение плотности потока нейтронного излучения в каналах до 12 %. Это более чем 15 % ниже, чем для загрузок, формируемых «ручным» способом (рисунок 2.5).

Таким образом, применение ГА для РСЭ реактора ИРТ-Т обеспечивает оптимизацию эксплуатационных характеристик активной зоны и процесса формирования схем загрузок, что позволяет сократить ресурсозатраты, повысить эффективности использования топлива в активной зоне и «стабильность» проводимых научных и производственных работ на базе экспериментальных устройств реактора.

4.4 Результаты и выводы по главе 4

Результаты исследований по разработке, конфигурированию и тестированию метода формирования оптимальных топливных загрузок активной зоны реактора ИРТ-Т, позволили сформулировать следующие выводы:

– проблема определения оптимальной топливной загрузки активной зоны классифицируется как NP-трудная задача. Предложено использовать популяционный генетический алгоритм, имитирующий процесс «эволюции» для поиска решений. Он устойчив к дискретным переменным и локальным экстремумам, что важно при одновременном анализе параметров выгорания, энерговыделения и запаса реактивности активной зоны;

– предложена формализация двухэтапных операторов модификаций, основанная на операциях скрещивания и мутаций для формирования топливных компоновок, и моделях прогнозирования значений КНРЭ и запаса реактивности. Направленный случайный поиск реализован за счет оригинальной функции приспособленности с целевыми функциями запаса реактивности и ОКНРЭ, а также функционального отбора и приоритизации наиболее «сильных» решений;

– разработана функция приспособленности и установлены закономерности формирования топливных загрузок в зависимости от рассматриваемых критериев оптимальности, что позволяет находить компоновки в пространстве решений с высокой размерностью.

– разработан метод регуляризации направленного поиска, учитывающий «условную» симметрию между ячейками, квантилями и сторонами активной зоны, для размещения близких по выгоранию и энерговыделению ТВС. Это позволило сохранить баланс между целевыми функциями запаса реактивности и ОКНРЭ, а также приблизить вид формируемых компоновок к реальным, что упрощает процедуру экспериментального профилирования;

– эффективность и корректность решений, формируемых ГА, была подтверждена на основе оптимизации реальных загрузок 2022-2023 гг. и последующим оценкой эксплуатационных характеристик. По результатам опытной эксплуатации ГА с прогнозными моделями в 2024 г. достигнуто увеличение продолжительности топливных циклов более чем на 11 %. Показано, что формирование схем загрузок по фиксированным критериям позволяет снизить перераспределение интенсивности нейтронного излучения в экспериментальных каналах до 12 % (снижение на более чем 15 %).

Заключение

По результатам, представленным в диссертационном исследовании, сформулированы основные выводы:

1. Для активной зоны исследовательского реактора ИРТ-Т характерны эффекты локального роста и перераспределения энерговыделения в топливных ячейках, что оказывает влияние на характеристики нейтронного излучения в экспериментальных устройствах, энергонапряженность твэлов и продолжительность топливной кампании. Для оптимизации текущего процесса РСЭ и эксплуатационных характеристик реактора ИРТ-Т предложена интеграция ПС MCU-PTR (метода Монте-Карло) и машинного обучения для создания суррогатных (прогнозных) моделей с целью «ускорения» трудоемких расчетных процессов, при сохранении точности. Для формирования топливной компоновки активной зоны предложено реализовать алгоритм поиска относительно критериев «оптимальности».

2. Разработан метод генерации нуклидного состава топлива, основанный на математической реконструкции ядерных концентраций. Подход учитывает неравномерности выгорания топлива в гетерогенной структуре активной зоны и тепловыделяющих элементов, что позволяет «воссоздавать» актуальный состав топлива расчетной модели. На основе сопоставления с эталонными расчетами определена средняя погрешность реконструкции нуклидного состава, которая составила не более 3 %, при погрешности определения КНРЭ в ячейках не более 4,6 %. Средняя точность пространственных распределений энерговыделения при реконструкции состава топлива составила 95 %. Сопоставление полученных результатов с экспериментальными данными реактора показало, что САО от запаса реактивности и критичности реактора не превышает $0,31 \beta_{эфф}$ и $0,38 \beta_{эфф}$, соответственно, при максимальной погрешности ПС MCU-PTR $\pm 2,5 \beta_{эфф}$.

3. Разработаны суррогатные модели для предсказания распределения энерговыделения в топливных ячейках, размножающих свойств активной зоны с учетом положений поглощающих стержней и максимальной энергонапряженности топливных элементов. Тестовая точность определения значений КНРЭ и запаса

реактивности на основе прогнозной модели (GBR) составила 98 % и 97 %, при CAO 0,014 и 0,33 $\beta_{эфф}$, соответственно. Точность прогнозов максимальной энергонапряженности в топливных ячейках на основе разработанного нейросетевого алгоритма (MLP_MTL + Residual-блок) составила 93 %, при CAO 0,037. Верификация моделей на основе SHAP-тестов и обобщенных зависимостей показала, что формируемые прогнозы интерпретируемы (объясняемый ИИ), устойчивы к «шумам» и адаптивны даже к незначительным изменениям. Валидация моделей проводилась на основе сопоставления с эталонными расчетами (аттестованная модель ПС MCU-PTR) и экспериментальными данными реактора ИРТ-Т: погрешность определения значений КНРЭ, запаса реактивности и критичности реактора составили 0,036, 0,39 $\beta_{эфф}$ и 0,51 $\beta_{эфф}$, соответственно, что не превышает паспортные погрешности аттестованной модели. Точность определения интегральной эффективности групп РО КО1 и КО2 составила 95 %, что свидетельствует о возможности применения разработанных моделей для определения характеристик реактора ИРТ-Т при РСЭ.

4. Разработан метод поиска топливных загрузок активной зоны реактора ИРТ-Т, включающий в себя перестановки с помощью механизмов генетического алгоритма и суррогатные модели для определения НФХ анализируемых решений. Тестирование метода проводилось на основе оптимизации «прошлых» топливных загрузок, сопоставлении с экспериментальными примерами и показало: алгоритм способен находить оптимальную загрузку, затрачивая от 60 до 120 секунд процессорного времени. Подход позволяет примерно в 240 раз сократить временные затраты на формирование компоновок, по сравнению с традиционным «ручным» методом. По результатам опытной эксплуатации на реакторе ИРТ-Т в 2024 г. метод позволил увеличить продолжительность топливных циклов более чем на 11 %, что свидетельствует о повышении экономической эффективности использования топлива. При использовании ГА изменение интенсивности нейтронного излучения в каналах при перегрузках снизилось с 20–35 % до 10–

15 %, что обуславливает повышение стабильности проводимых научных и производственных работ на реакторе ИРТ-Т.

5. Результаты диссертационного исследования имеют потенциал для адаптации относительно существующих исследовательских реакторов с целью оптимизации эксплуатационных характеристик, а также могут быть использованы для разработки новых программных пакетов и комплексов для расчетного сопровождения эксплуатации ядерных реакторов.

Список используемых сокращений и аббревиатур

MCU	–	Monte-Carlo Universal
MCU-PTR	–	Monte Carlo Universal Pool-Type Reactor
БА	–	Биологические алгоритмы
ВИ	–	Вычислительный интеллект
ВЭК	–	Вертикальный экспериментальный канал
ГА	–	Генетический алгоритм
ГО	–	Глубокое обучение
ГЭК	–	Горизонтальный экспериментальный канал
ИИ	–	Искусственный интеллект
ИНС	–	Искусственная нейронная сеть
ИРТ-Т	–	Исследовательский реактор типовой Томский
ИЯР	–	Исследовательский ядерный реактор
КНРЭ	–	Коэффициент неравномерности распределения энерговыделения
НЛ	–	Нечеткая логика
ММК	–	Метод Монте-Карло
МО	–	Машинное обучение
НФХ	–	Нейтронно-физические характеристики
ОКНРЭ	–	Объемный коэффициент неравномерности распределения энерговыделения
ПС	–	Программное средство
РО	–	Рабочий орган
РСЭ	–	Расчетное сопровождение эксплуатации
САО	–	Средняя абсолютная ошибка
СОО	–	Средняя относительная ошибка
СУЗ	–	Система управления и защиты
ТВС	–	Тепловыделяющая сборка
ЯУ	–	Ядерная установка

Список литературы

1. Haghghat A. Monte Carlo Methods for Particle Transport / A. Haghghat. – 2. – Second edition. | Boca Raton : CRC Press, 2021.: CRC Press, 2020.
2. Data-driven Approaches to Surrogate Machine Learning Model Development / H.R. Jones [и др.] arXiv:2210.02631 [cs]. – arXiv, 2022.
3. Hall J.S. Further Reflections on the Timescale of AI / J.S. Hall // Algorithmic Probability and Friends. Bayesian Prediction and Artificial Intelligence : Lecture Notes in Computer Science / сост. D. Hutchison [и др.]; ред. D.L. Dowe. – Berlin, Heidelberg: Springer Berlin Heidelberg, 2013. – Т. 7070. – С. 174-183.
4. Rosenblatt F. The perceptron: A probabilistic model for information storage and organization in the brain. / F. Rosenblatt // Psychological Review. – 1958. – Vol. 65. – The perceptron. – № 6. – P. 386-408.
5. Ruder S. An overview of gradient descent optimization algorithms / S. Ruder arXiv:1609.04747 [cs]. – arXiv, 2017.
6. Machine Learning Paradigms: Advances in Learning Analytics : Intelligent Systems Reference Library. Vol. 158. Machine Learning Paradigms / eds. M. Virvou [et al.]. – Cham: Springer International Publishing, 2020.
7. Buckley J.J. Fuzzy neural networks: A survey / J.J. Buckley, Y. Hayashi // Fuzzy Sets and Systems. – 1994. – Vol. 66. – Fuzzy neural networks. – № 1. – P. 1-13.
8. Suman S. Artificial intelligence in nuclear industry: Chimera or solution? / S. Suman // Journal of Cleaner Production. – 2021. – Vol. 278. – Artificial intelligence in nuclear industry. – P. 124022.
9. Guo Z. Use of Artificial Neural Networks to Analyze Nuclear Power Plant Performance / Z. Guo, R.E. Uhrig // Nuclear Technology. – 1992. – Vol. 99. – № 1. – P. 36-42.
10. Real-time Nuclear Power Plant Monitoring with Neural Network / K. Nabeshima [et al.] // Journal of Nuclear Science and Technology. – 1998. – Vol. 35. – № 2. – P. 93-100.
11. Machine learning based system performance prediction model for reactor control / Y. Zeng [et al.] // Annals of Nuclear Energy. – 2018. – Vol. 113. – P. 270-278.

12. Nuclear energy system's behavior and decision making using machine learning / M. Gomez Fernandez [et al.] // Nuclear Engineering and Design. – 2017. – Vol. 324. – P. 27-34.
13. Contardo J.M.C. Predicting nuclear fuel parameters by using machine learning techniques / J.M.C. Contardo, X.A. Lopez-Cortes, I. Merino // 2021 40th International Conference of the Chilean Computer Science Society (SCCC) 2021 40th International Conference of the Chilean Computer Science Society (SCCC). – La Serena, Chile: IEEE, 2021. – C. 1-5.
14. Machine learning-assisted surrogate construction for full-core fuel performance analysis / Y. Che [et al.] // Annals of Nuclear Energy. – 2022. – Vol. 168. – P. 108905.
15. Integrating core physics and machine learning for improved parameter prediction in boiling water reactor operations / M.R. Oktavian [et al.] // Scientific Reports. – 2024. – Vol. 14. – № 1. – P. 5835.
16. Nuclear power plant components condition monitoring by probabilistic support vector machine / J. Liu [et al.] // Annals of Nuclear Energy. – 2013. – Vol. 56. – P. 23-33.
17. Hobold G.M. Machine learning classification of boiling regimes with low speed, direct and indirect visualization / G.M. Hobold, A.K. da Silva // International Journal of Heat and Mass Transfer. – 2018. – Vol. 125. – P. 1296-1309.
18. Filho L.P. USING NEURAL NETWORKS FOR PREDICTION OF NUCLEAR PARAMETERS / L.P. Filho, K.C. Souto, M.D. Machado. – 2013. – P. 11.
19. Artificial neural network for predicting nuclear power plant dynamic behaviors / M. El-Sefy [и др.] // Nuclear Engineering and Technology. – 2021. – T. 53. – № 10. – C. 3275-3285.
20. Cognitive Behavioral Model of an Operation Crew in the Main Control Room of a Nuclear Power Plant Based on a State-Oriented Procedure / T. Qing [et al.] // Processes. – 2022. – Vol. 10. – № 2. – P. 182.

21. Palmi K. Prediction of the evolution of the nuclear reactor core parameters using artificial neural network / K. Palmi, W. Kubinski, P. Darnowski arXiv:2304.10337 [cs]. – arXiv, 2023.
22. Marseguerra M. MODEL IDENTIFICATION BY NEURO-FUZZY TECHNIQUES: PREDICTING THE WATER LEVEL IN A STEAM GENERATOR OF A PWR / M. Marseguerra, E. Zio, P. Avogadri.
23. Prediction of time series of NPP operating parameters using dynamic model based on BP neural network / Y. Liu [et al.] // *Annals of Nuclear Energy*. – 2015. – Vol. 85. – P. 566-575.
24. On-line monitoring of instrument channel performance in nuclear power plant using PEANO / P.F. Fantoni [et al.] // *Progress in Nuclear Energy*. – 2003. – Vol. 43. – № 1-4. – P. 83-89.
25. Lee G. A convolutional neural network model for abnormality diagnosis in a nuclear power plant / G. Lee, S.J. Lee, C. Lee // *Applied Soft Computing*. – 2021. – Vol. 99. – P. 106874.
26. Mwaura A.M. Adaptive Neuro-Fuzzy Inference System (ANFIS) based modelling of incipient steam generator tube rupture diagnosis / A.M. Mwaura, Y.-K. Liu // *Annals of Nuclear Energy*. – 2021. – Vol. 157. – P. 108262.
27. Morten L. Control functions in MFM: basic principles / L. Morten. – 2011. – Vol. 2. – № 2.
28. Lind M. FUNCTIONAL MODELLING FOR FAULT DIAGNOSIS AND ITS APPLICATION FOR NPP / M. Lind, X. Zhang // *Nuclear Engineering and Technology*. – 2014. – Vol. 46. – № 6. – P. 753-772.
29. Suryono T.J. The Desirable Features of Computer Based Emergency Operating Procedure for Nuclear Power Operation / T.J. Suryono, A. Gofuku // *IFAC-PapersOnLine*. – 2016. – Vol. 49. – № 19. – P. 403-407.
30. Zhou C. Validation of the modified ATHLET code with the natural convection test of the PHENIX reactor / C. Zhou, K. Huber, X. Cheng // *Annals of Nuclear Energy*. – 2013. – Vol. 59. – P. 31-46.

31. Verification of RELAP5-3D code in natural circulation loop as function of the initial water inventory / C. Bertani [et al.] // *Journal of Physics: Conference Series*. – 2017. – Vol. 923. – P. 012008.
32. Kozmenkov Y. Validation of the RELAP5 code for the modeling of flashing-induced instabilities under natural-circulation conditions using experimental data from the CIRCUS test facility / Y. Kozmenkov, U. Rohde, A. Manera // *Nuclear Engineering and Design*. – 2012. – Vol. 243. – P. 168-175.
33. Capability of the Best Estimate Code RELAP5/Mod 3.2 to Analyze the Steady State and Stability of Boiling Two-Phase Natural Circulation Systems / M.R. Gartia [et al.]. – 2007.
34. Hou X. Capability of RELAP5 code to simulate the thermal-hydraulic characteristics of open natural circulation / X. Hou, Z. Sun, W. Lei // *Annals of Nuclear Energy*. – 2017. – Vol. 109. – P. 612-625.
35. Fiori F. Assessment study of RELAP5/SCDAP capability to reproduce TALL facility thermal hydraulic behavior / F. Fiori, Z.W. Zhou // *Nuclear Engineering and Design*. – 2015. – Vol. 295. – P. 15-26.
36. Gomes C.R. Neural network of Gaussian radial basis functions applied to the problem of identification of nuclear accidents in a PWR nuclear power plant / C.R. Gomes, J.A.C. Canedo Medeiros // *Annals of Nuclear Energy*. – 2015. – Vol. 77. – P. 285-293.
37. Prediction of hydrogen concentration in containment during severe accidents using fuzzy neural network / D.Y. Kim [et al.] // *Nuclear Engineering and Technology*. – 2015. – Vol. 47. – № 2. – P. 139-147.
38. Reactor Vessel Water Level Estimation During Severe Accidents Using Cascaded Fuzzy Neural Networks / D.Y. Kim [et al.] // *Nuclear Engineering and Technology*. – 2016. – Vol. 48. – № 3. – P. 702-710.
39. Estimation of LOCA Break Size Using Cascaded Fuzzy Neural Networks / G.P. Choi [et al.] // *Nuclear Engineering and Technology*. – 2017. – Vol. 49. – № 3. – P. 495-503.

40. A study on the robustness of neural network models for predicting the break size in LOCA / X. Tian [et al.] // *Progress in Nuclear Energy*. – 2018. – Vol. 109. – P. 12-28.
41. Detection of fuel failure in pressurized water reactor with artificial neural network / B. Dong [et al.] // *Annals of Nuclear Energy*. – 2020. – Vol. 140. – P. 107104.
42. Koo Y.D. Nuclear reactor vessel water level prediction during severe accidents using deep neural networks / Y.D. Koo // *Nuclear Engineering and Technology*. – 2019. – P. 8.
43. Baraldi P. Unsupervised Clustering for Fault Diagnosis in Nuclear Power Plant Components: / P. Baraldi, F. Di Maio, E. Zio // *International Journal of Computational Intelligence Systems*. – 2013. – Vol. 6. – Unsupervised Clustering for Fault Diagnosis in Nuclear Power Plant Components. – № 4. – P. 764.
44. Fault Detection in Nuclear Power Plants Components by a Combination of Statistical Methods / F. Di Maio [et al.] // *IEEE Transactions on Reliability*. – 2013. – Vol. 62. – № 4. – P. 833-845.
45. Miki D. Bearing fault diagnosis using weakly supervised long short-term memory / D. Miki, K. Demachi // *Journal of Nuclear Science and Technology*. – 2020. – Vol. 57. – № 9. – P. 1091-1100.
46. Ensemble Learning-based Fault Detection in Nuclear Power Plant Screen Cleaners / A. Deleplace [et al.] // *IFAC-PapersOnLine*. – 2020. – Vol. 53. – № 2. – P. 10354-10359.
47. Improvement of fault diagnosis efficiency in nuclear power plants using hybrid intelligence approach / Y. Liu [et al.] // *Progress in Nuclear Energy*. – 2014. – Vol. 76. – P. 122-136.
48. Hatami E. Design of a fault tolerated intelligent control system for load following operation in a nuclear power plant / E. Hatami, N. Vosoughi, H. Salarieh // *International Journal of Electrical Power & Energy Systems*. – 2016. – Vol. 78. – P. 864-872.

49. Research on intelligent fault diagnosis method for nuclear power plant based on correlation analysis and deep belief network / B.-S. Peng [et al.] // *Progress in Nuclear Energy*. – 2018. – Vol. 108. – P. 419-427.
50. A robust strategy for sensor fault detection in nuclear power plants based on principal component analysis / S. Zhu [et al.] // *Annals of Nuclear Energy*. – 2021. – Vol. 164. – P. 108621.
51. Ayodeji A. SVR optimization with soft computing algorithms for incipient SGTR diagnosis / A. Ayodeji, Y. Liu // *Annals of Nuclear Energy*. – 2018. – Vol. 121. – P. 89-100.
52. Ghazali A.B. Fault detection and analysis in nuclear research facility using artificial intelligence methods / A.B. Ghazali, M.M. Ibrahim // *ADVANCING NUCLEAR SCIENCE AND ENGINEERING FOR SUSTAINABLE NUCLEAR ENERGY INFRASTRUCTURE: Proceeding of the International Nuclear Science, Technology and Engineering Conference 2015 (iNuSTEC2015)*. – Negeri Sembilan, Malaysia, 2016. – P. 030010.
53. Supercritical water heat transfer coefficient prediction analysis based on BP neural network / D. Ma [и др.] // *Nuclear Engineering and Design*. – 2017. – T. 320. – C. 400-408.
54. A machine learning approach to thermal conductivity modeling: A case study on irradiated uranium-molybdenum nuclear fuels / E.J. Kautz [et al.] // *Computational Materials Science*. – 2019. – Vol. 161. – A machine learning approach to thermal conductivity modeling. – P. 107-118.
55. Bang H.-T. Application of machine learning methods to predict a thermal conductivity model for compacted bentonite / H.-T. Bang, S. Yoon, H. Jeon // *Annals of Nuclear Energy*. – 2020. – Vol. 142. – P. 107395.
56. Akay O.E. Modeling the total heat transfer coefficient of a nuclear research reactor cooling system by different methods / O.E. Akay, M. Das // *Case Studies in Thermal Engineering*. – 2021. – Vol. 25. – P. 100914.

57. Pirouzman A. Estimation of relative power distribution and power peaking factor in a VVER-1000 reactor core using artificial neural networks / A. Pirouzman, M. Kazem Dehdashti // *Progress in Nuclear Energy*. – 2015. – Vol. 85. – P. 17-27.
58. AI-based design of a nuclear reactor core / V. Sobes [et al.] // *Scientific Reports*. – 2021. – Vol. 11. – № 1. – P. 19646.
59. Development of in-core fuel management tool for AHWR using artificial neural networks / A. Thakur [и др.] // *Annals of Nuclear Energy*. – 2021. – Т. 150. – С. 107869.
60. Shahmirzaei A. Assessment of gadolinium concentration effects on the NuScale reactor parameters and optimizing the fuel composition via machine learning method / A. Shahmirzaei, G.R. Ansarifar, A. Koraniyany // *International Journal of Energy Research*. – 2022. – P. er.7760.
61. Deep learning approach to nuclear fuel transmutation in a fuel cycle simulator / J.W. Bae [и др.] // *Annals of Nuclear Energy*. – 2020. – Т. 139. – С. 107230.
62. Enhancing nuclear data validation analysis by using machine learning / D. Neudecker [и др.] // *Nuclear Data Sheets*. – 2020. – Т. 167. – С. 36-60.
63. Machine learning of LWR spent nuclear fuel assembly decay heat measurements / B. Ebiwonjumi [et al.] // *Nuclear Engineering and Technology*. – 2021. – Vol. 53. – № 11. – P. 3563-3579.
64. Zhu X. Predicting the Irradiation Swelling of Austenitic and Ferritic/Martensitic Steels, Based on the Coupled Model of Machine Learning and Rate Theory / X. Zhu, X. Li, M. Zheng // *Metals*. – 2022. – Vol. 12. – № 4. – P. 651.
65. Vicente-Valdez P. Nuclear data evaluation augmented by machine learning / P. Vicente-Valdez, L. Bernstein, M. Fratoni // *Annals of Nuclear Energy*. – 2021. – Vol. 163. – P. 108596.
66. Yescas M. Prediction of mechanical properties of PWR vessel steel heads containing residual carbon macrosegregation using Artificial Neural Networks / M. Yescas, B. Le Gloannec, F. Roch // *Journal of Nuclear Materials*. – 2022. – Vol. 558. – P. 153360.

67. Lin C. Automatic fuel lattice design in a boiling water reactor using a particle swarm optimization algorithm and local search / C. Lin, T.-H. Lin // *Annals of Nuclear Energy*. – 2012. – Vol. 47. – P. 98-103.

68. Kumar A. A new approach to nuclear reactor design optimization using genetic algorithms and regression analysis / A. Kumar, P.V. Tsvetkov // *Annals of Nuclear Energy*. – 2015. – Vol. 85. – P. 27-35.

69. Methodology for integrated fuel lattice and fuel load optimization using population-based metaheuristics and decision trees / J.J. Ortiz-Servin [et al.] // *Progress in Nuclear Energy*. – 2018. – Vol. 104. – P. 264-270.

70. Seurin P. Assessment of Reinforcement Learning Algorithms for Nuclear Power Plant Fuel Optimization / P. Seurin, K. Shirvan arXiv:2305.05812 [physics]. – arXiv, 2023.

71. De Oliveira I.M.S. Swarm intelligence of artificial bees applied to In-Core Fuel Management Optimization / I.M.S. De Oliveira, R. Schirru // *Annals of Nuclear Energy*. – 2011. – Vol. 38. – № 5. – P. 1039-1045.

72. Fuel lattice design in a boiling water reactor using an ant-colony-based system / J.L. Montes [et al.] // *Annals of Nuclear Energy*. – 2011. – Vol. 38. – № 6. – P. 1327-1338.

73. Martín-del-Campo C. Advanced and flexible genetic algorithms for BWR fuel loading pattern optimization / C. Martín-del-Campo, M.-Á. Palomera-Pérez, J.-L. François // *Annals of Nuclear Energy*. – 2009. – Vol. 36. – № 10. – P. 1553-1559.

74. Pazirandeh A. Optimizing the fuel management in a VVER-1000 reactor using an artificial neural network / A. Pazirandeh, S. Tayefi // *Annals of Nuclear Energy*. – 2012. – Vol. 42. – P. 112-118.

75. Liu S. Studies of fuel loading pattern optimization for a typical pressurized water reactor (PWR) using improved pivot particle swarm method / S. Liu, J. Cai // *Annals of Nuclear Energy*. – 2012. – Vol. 50. – P. 117-125.

76. Application of Genetic Algorithm methodologies in fuel bundle burnup optimization of Pressurized Heavy Water Reactor / M.L. Jayalal [et al.] // *Nuclear Engineering and Design*. – 2015. – Vol. 281. – P. 58-71.

77. Ahmad A. Optimization of fuel loading pattern for a material test reactor using swarm intelligence / A. Ahmad, S.-I. Ahmad // Progress in Nuclear Energy. – 2018. – Vol. 103. – P. 45-50.
78. Shams S. Fuel assemblies loading pattern optimization of pressurized water reactors using the trees social relations algorithm / S. Shams, H. Azgomi, A. Asghari // Annals of Nuclear Energy. – 2023. – Vol. 192. – P. 109963.
79. Reactor Core Loading Pattern Optimization with Reinforcement Learning / G.K. Delipei [et al.]. – 2023.
80. A novel multi-objective optimization method, imperialist competitive algorithm, for fuel loading pattern of nuclear reactors / R. Akbari [et al.] // Progress in Nuclear Energy. – 2018. – Vol. 108. – P. 391-397.
81. Glukhov G.G. The IRT-T reactor at Tomsk Polytechnical Institute Nuclear Physics Research Institute: Research and applications / G.G. Glukhov, A.N. Didenko // Soviet Atomic Energy. – 1988. – Vol. 64. – The IRT-T reactor at Tomsk Polytechnical Institute Nuclear Physics Research Institute. – № 5. – P. 423-426.
82. Capability assessment of production of n.c.a. isotope ^{177}Lu on the average flux reactor IRT-T / D.V. Kabanov [et al.] // Journal of Physics: Conference Series. – 2022. – Vol. 2147. – № 1. – P. 012019.
83. The status of MCU-5 / N.I. Alekseev [et al.] // Physics of Atomic Nuclei. – 2012. – Vol. 75. – № 14. – P. 1634-1646.
84. Thermal analysis of IRT-T reactor fuel elements / A. Naymushin [et al.] // IOP Conference Series: Materials Science and Engineering. – 2015. – Vol. 93. – P. 012002.
85. A. Naymushin*, M. Anikin, I. Lebedev, A. Busygin, S. Dmitriev and D. Zolotykh. Features of Fuel Burnup Calculations for Irt-T Reactor Using Mcu-Ptr Code / A. Naymushin*, M. Anikin, I. Lebedev, A. Busygin, S. Dmitriev and D. Zolotykh // J. Industr. Pollut. Contr. – 2016. – T. 32. – № No. 2. – C. 449-452.
86. Shchurovskaya M.V. Control rod calibration simulation using Monte Carlo code for the IRT-type research reactor / M.V. Shchurovskaya // Annals of Nuclear Energy. – 2016.

87. Validation of the MCU-PTR computational model of beryllium poisoning using selected experiments at the IRT-T research reactor / M.V. Shchurovskaya [et al.] // *Annals of Nuclear Energy*. – 2018. – Vol. 113. – P. 436-445.
88. Calculation and Experimental Determination of the Neutronics Characteristics of the IRT-T Research Reactor / N.V. Smol'nikov [et al.] // *Atomic Energy*. – 2021. – Vol. 131. – № 1. – P. 42-45.
89. Расчетно-экспериментальное определение нейтронно-физических характеристик исследовательского реактора ИРТ-Т / Н.В. Смольников [и др.] // *Атомная энергия*. – 2021. – Т. 131. – № 1. – С. 43-46.
90. Smolnikov N. Monitoring of the Efficiency of the IRT-T Reactor Heat Exchanger System by Machine Learning Method / N. Smolnikov, M. Kublinskiy, A. Naimushin // *Physics of Particles and Nuclei Letters*. – 2024. – Vol. 21. – № 4. – P. 808-810.
91. Smolnikov N. Supervised machine learning with regression for the IRT-T reactor cooling system / N. Smolnikov, M. Kublinskiy, A. Naymushin // *ITM Web of Conferences*. – 2024. – Т. 59. – С. 03007.
92. Substantiation of the Possibility to Obtain ^{177}Lu on the Average Flux Research Reactor IRT-T / N.V. Smol'nikov [et al.] // *Journal of Engineering Physics and Thermophysics*. – 2024. – Vol. 97. – № 6. – P. 1478-1487.
93. Computational and experimental determination of neutron flux density and gamma radiation dose rate at the IRT-T reactor for neutron capture therapy / N.V. Smolnikov [и др.] // *Izvestiya vysshikh uchebnykh zavedenii. Fizika*. – 2024. – Т. 67. – № 3. – С. 74-81.
94. Conceptual Design of Experimental Facility for Large-Diameter NTD-Si at the IRT-T Reactor / N.V. Smolnikov [и др.] // *Atom Indonesia*. – 2021. – Т. 47. – № 1. – С. 39.
95. Талиев А.В. Модернизированная программа ASTRA для расчета тепловых режимов ТВС исследовательских реакторов с трубчатыми коаксиальными твэлами / Талиев А.В. // *Препринт ИАЭ-6405/5*. – 2006.

96. Duderstadt, J.J., Hamilton, L.J. Nuclear Reactor Analysis / Duderstadt, J.J., Hamilton, L.J. – John Wiley and Sons, Inc., 1976. – 563 с.
97. Панин М.П. Моделирование переноса излучения : Учебное пособие / Панин М.П. – МИФИ, 2008. – 212 с.
98. Gaussian Process Based Prediction of Density Distribution in Core of Research Nuclear Reactor / N.V. Smolnikov [et al.] // Moscow University Physics Bulletin. – 2024. – Vol. 79. – № S2. – P. S935-S943.
99. Pearson's Correlation Coefficient // Encyclopedia of Public Health / ed. W. Kirch. – Dordrecht: Springer Netherlands, 2008. – P. 1090-1091.
100. Gross E. Practical Statistics for High Energy Physics / E. Gross // CERN Yellow Reports: School Proceedings. – 2017. – P. 165 Pages.
101. Brownlee J. Statistical Methods for Machine Learning / J. Brownlee.
102. Ronald L. Wasserstein & Nicole A. Lazar. The ASA Statement on p-Values: Context, Process, and Purpose / Ronald L. Wasserstein & Nicole A. Lazar // The American Statistician. – 2016. – Т. 70. – № 2. – С. 129-133.
103. Razali N.M. Power comparisons of Shapiro-Wilk, Kolmogorov-Smirnov, Lilliefors and Anderson-Darling tests / N.M. Razali, Y.B. Wah.
104. Thadewald T. Jarque–Bera Test and its Competitors for Testing Normality – A Power Comparison / T. Thadewald, H. Büning // Journal of Applied Statistics. – 2007. – Vol. 34. – № 1. – P. 87-105.
105. Sullivan G.M. Using Effect Size—or Why the *P* Value Is Not Enough / G.M. Sullivan, R. Feinn // Journal of Graduate Medical Education. – 2012. – Vol. 4. – № 3. – P. 279-282.
106. Cumming G. The New Statistics: Why and How / G. Cumming // Psychological Science. – 2014. – Vol. 25. – The New Statistics. – № 1. – P. 7-29.
107. Brophy A.L. An algorithm and program for calculation of Kendall's rank correlation coefficient / A.L. Brophy // Behavior Research Methods, Instruments, & Computers. – 1986. – Vol. 18. – № 1. – P. 45-46.
108. Nuclear Reactor Design : An Advanced Course in Nuclear Engineering. Vol. 2 / ed. Y. Oka. – Tokyo: Springer Japan, 2014.

109. Pirouzmand A. Calculation of radial burnup and nuclides atom density distributions in a VVER-1000 fuel rod using Monte Carlo method / A. Pirouzmand, F. Roosta // *Progress in Nuclear Energy*. – 2016. – Vol. 88. – P. 321-331.

110. Stacey W.M. *Nuclear Reactor Physics* / W.M. Stacey. – 1. – Wiley, 2007.

111. Control Rod Calibration and Worth Calculation for Optimized Power Reactor 1000 (OPR-1000) Using Core Simulator OPR1000 / N.A. Son [и др.] // *World Journal of Nuclear Science and Technology*. – 2017. – Т. 07. – № 01. – С. 15-23.

112. Control Rod Modeling and Worth Calculation for a Typical 1100 MWe Nuclear Power Plant Using WIMS/D4 and CITATION / I. Shahid [et al.] // *Science and Technology of Nuclear Installations*. – 2022. – Vol. 2022. – P. 1-13.

113. Н.В. Смольников, М.Н. Аникин, И.И. Лебедев, А.Г. Наймушин, Применение алгоритмов машинного обучения для прогнозирования неравномерности распределения энерговыделения в активной зоне исследовательского реактора ИРТ-Т / Н.В. Смольников, М.Н. Аникин, И.И. Лебедев, А.Г. Наймушин, И.А. Ушаков, Д.В. Пасько // *ВАНТ. Сер. Физика ядерных реакторов*,. – 2024. – Т. 5. – С. 32-50.

114. Shorten C. A survey on Image Data Augmentation for Deep Learning / C. Shorten, T.M. Khoshgoftaar // *Journal of Big Data*. – 2019. – Vol. 6. – № 1. – P. 60.

115. Comparing the performance of machine learning algorithms using estimated accuracy / S. Gupta [et al.] // *Measurement: Sensors*. – 2022. – Vol. 24. – P. 100432.

116. Giudici P. Machine Learning Classification Model Comparison / P. Giudici, A. Gramegna, E. Raffinetti // *Socio-Economic Planning Sciences*. – 2023. – Vol. 87. – P. 101560.

117. An Empirical Comparison of Machine Learning Models for Time Series Forecasting / N.K. Ahmed [et al.] // *Econometric Reviews*. – 2010. – Vol. 29. – № 5-6. – P. 594-621.

118. Rahman S.Md.M. Introducing Ensemble Machine Learning Algorithms for Automatic Test Case Generation using Learning Based Testing / S.Md.M. Rahman, N.U. Eisty. – arXiv, 2024.

119. Briscoe E. Conceptual complexity and the bias/variance tradeoff / E. Briscoe, J. Feldman // *Cognition*. – 2011. – Vol. 118. – № 1. – P. 2-16.
120. Chen T. XGBoost: A Scalable Tree Boosting System / T. Chen, C. Guestrin // *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining KDD '16: The 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. – San Francisco California USA: ACM, 2016. – XGBoost. – P. 785-794.
121. LaValle S.M. On the Relationship between Classical Grid Search and Probabilistic Roadmaps / S.M. LaValle, M.S. Branicky // *Algorithmic Foundations of Robotics V : Springer Tracts in Advanced Robotics* / ред. J.-D. Boissonnat [и др.]. – Berlin, Heidelberg: Springer Berlin Heidelberg, 2004. – Т. 7. – С. 59-75.
122. Caruana R. Multitask Learning / R. Caruana // *Machine Learning*. – 1997. – Т. 28. – № 1. – С. 41-75.
123. Deep Residual Learning for Image Recognition / К. He [и др.]. – arXiv, 2015.
124. Lundberg S. A Unified Approach to Interpreting Model Predictions / S. Lundberg, S.-I. Lee. – arXiv, 2017.
125. Grabisch M. An axiomatic approach to the concept of interaction among players in cooperative games / M. Grabisch, M. Roubens // *International Journal of Game Theory*. – 1999. – Т. 28. – № 4. – С. 547-565.
126. Katoch S. A review on genetic algorithm: past, present, and future / S. Katoch, S.S. Chauhan, V. Kumar // *Multimedia Tools and Applications*. – 2021. – Vol. 80. – A review on genetic algorithm. – № 5. – P. 8091-8126.
127. Slowik A. Evolutionary algorithms and their applications to engineering problems / A. Slowik, H. Kwasnicka // *Neural Computing and Applications*. – 2020. – Vol. 32. – № 16. – P. 12363-12379.
128. Alhijawi B. Genetic algorithms: theory, genetic operators, solutions, and applications / B. Alhijawi, A. Awajan // *Evolutionary Intelligence*. – 2024. – Vol. 17. – Genetic algorithms. – № 3. – P. 1245-1256.

129. Coello Coello C.A. Evolutionary Algorithms for Solving Multi-Objective Problems : Genetic Algorithms and Evolutionary Computation. Vol. 5 / C.A. Coello Coello, D.A. Van Veldhuizen, G.B. Lamont; coll. D.E. Goldberg. – Boston, MA: Springer US, 2002.

130. Multi-objective Evolutionary Optimisation for Product Design and Manufacturing / eds. L. Wang, A.H.C. Ng, K. Deb. – London: Springer London, 2011.

131. Эвристический алгоритм профилирования неоднородности энерговыделения в активной зоне реактора ИРТ-Т / Смольников Н. В [и др.] // Вопросы атомной науки и техники. Серия: Ядерно-реакторные константы. – 2025. – № 2. – С. 17-28.