

Оценка нейтронно-физических характеристик исследовательского ядерного реактора ИРТ-Т на основе суррогатных моделей

Н. В. Смольников, М. Н. Аникин, И. И. Лебедев,
А. Г. Наймушин, И. А. Ушаков, Д. В. Пасько

Томский политехнический университет

Аннотация. В данном исследовании представлен подход на основе машинного обучения для оптимизации расчетного сопровождения эксплуатации исследовательского реактора ИРТ-Т. Разработаны модель гребневой регрессии (Ridge), модель регрессии на основе гауссовских процессов (GPR) с комбинированной ковариационной функцией (RBF + белый шум) и многозадачная архитектура нейронной сети (MLP_MTL) с применением остаточного обучения (residual learning). Данный подход позволяет прогнозировать распределения плотности энерговыделения и реактивные характеристики реактора, учитывая геометрические различия между стандартными и детализированными моделями активной зоны. При оценке запаса реактивности на тестовой выборке модель гребневой регрессии продемонстрировала коэффициент детерминации более 0,98 и среднюю абсолютную ошибку не более 0.18. Нейросетевая модель «MLP_MTL + остаточный блок» (Residual block) позволила достичь значения коэффициента детерминации не менее 0.91 при средней абсолютной ошибке 0.39, продемонстрировав превосходную способность локализовать зоны повышенного энерговыделения в твэлах при использовании крайне малого набора данных (40 примеров). Результаты работы показывают, что предложенный метод обеспечивает эффективный баланс между вычислительной производительностью и точностью, делая возможным надежный мониторинг активной зоны в условиях ограниченного объема обучающих данных.

Ключевые слова: ядерный реактор, машинное обучение, суррогатная модель, нейросеть, остаточное обучение

I. ВВЕДЕНИЕ

Обеспечение ядерной безопасности и оптимизация топливных циклов исследовательских реакторов требует точного знания распределения энерговыделения и запаса реактивности. Однако прецизионное моделирование (Монте-Карло) этих параметров в гетерогенной среде с учетом выгорания и положения органов регулирования является вычислительно сложной задачей, требующей от 10 до 40 часов расчетного времени. Суррогатное моделирование на базе нейронных сетей выступает эффективным инструментом, позволяющим аппроксимировать многомерные зависимости и получать результаты в режиме реального времени.

II. РЕАКТОР ИРТ-Т И СТАТИСТИЧЕСКИЙ АНАЛИЗ РАСПРЕДЕЛЕНИЙ ПАРАМЕТРОВ АКТИВНОЙ ЗОНЫ

Реактор ИРТ-Т – среднеточный исследовательский ядерный реактор бассейнового типа тепловой мощностью 6 МВт, введен в эксплуатацию после

масштабной модернизации в 1984 году [1]. Реактор предназначен для проведения научно-исследовательских работ в области физики твердого тела, нейтронно-активационному анализу, нейтронно-трансмутационному легированию кремния [2].

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.




Рис. 1. Картограмма активной зоны реактора ИРТ-Т: — восьмитрубная ТВС; — бериллиевый блок; — шеститрубная ТВС с каналом для стержня СУЗ; — вертикальный экспериментальный канал

Для построения адекватных прогностических моделей необходимо понимание статистических распределений входных данных. На основе моделирования более 120 состояний активной зоны реактора ИРТ-Т в ПС MCU-PTR был проведен анализ распределений глубины выгорания топлива и коэффициентов неравномерности (КНРЭ). Использование гауссовской модели с оцененными параметрами (1) для генерации топливных загрузок позволило получить выборку, содержащую более 2700 компоновок, в которых среднее значение глубины выгорания по зоне варьируется от 27% до 42% (рис. 2), что соответствует реальным условиям эксплуатации [3].

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

где: θ_1, θ_2 – неизвестные параметры модели (среднее значение и стандартное отклонение); σ_e – оцененное

стандартное отклонение; μ_e – оцененное среднее значение.

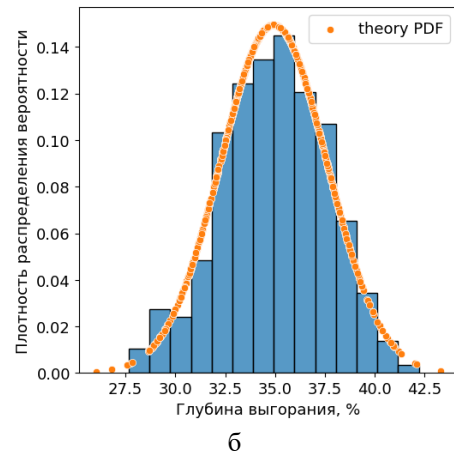
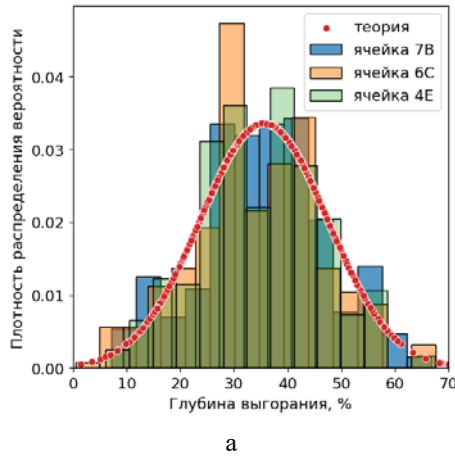


Рис. 2. Распределения значений глубины выгорания: а – некоторые ячейки активной зоны; б – среднее по топливным загрузкам (выборке)

III. СРАВНИТЕЛЬНЫЙ АНАЛИЗ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ И АНСАМБЛЕВЫХ ПОДХОДОВ

На первом этапе разработки суррогатных моделей была проведена оценка классических алгоритмов регрессии на данных упрощенной геометрии (без азимутального разбиения твэлов). Оценивались методы Ridge, Lasso, SVR и деревья решений (DTR).

Алгоритм	R^2 по ячейкам	Значения КНРЭ		Максимальное CAO в ячейке
		Минимальное R^2 в ячейке	CAO по ячейкам	
SVM		0,88		0,87
KNN		-1,16		2,35
GPR		-0,52		–
DTR		0,91		0,69

ТАБЛИЦА I. РЕЗУЛЬТАТЫ ПРОГНОЗОВ «СРЕДНИХ» МОДЕЛЕЙ НА ТЕСТОВОЙ ВЫБОРКЕ

Алгоритм	R^2 по ячейкам	Значения КНРЭ		
		Минимальное R^2 в ячейке	CAO по ячейкам	Максимальное CAO в ячейке
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	CAO, $\beta_{эфф}$
Ridge	0,93	0,59
Lasso	0,49	3,18

Как показано в табл. 1, линейные модели с L2-регуляризацией (Ridge) продемонстрировали неплохую сходимость ($R^2 \approx 0,91$), однако оказались чувствительны к флуктуациям в данных. Применение ансамблевого метода градиентного бустинга (GBR) позволило снизить среднюю абсолютную ошибку (CAO) на 28% относительно Ridge-модели. Внедрение штрафной регуляризации в структуру ансамбля обеспечило стабилизацию прогнозов и достижение точности $R^2 \approx 0,98$ для КНРЭ (рисунок 3). Тем не менее, данные подходы требуют полной переподготовки моделей при любом изменении расчетной геометрии, что ограничивает их универсальность [4].

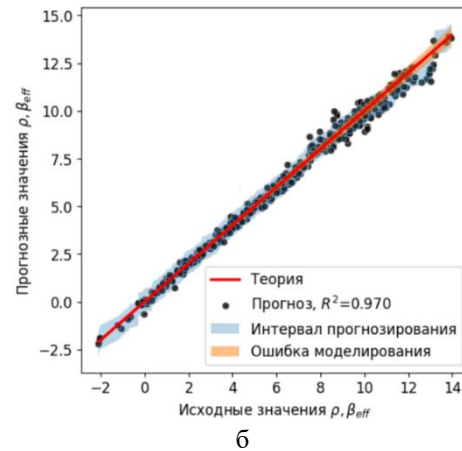
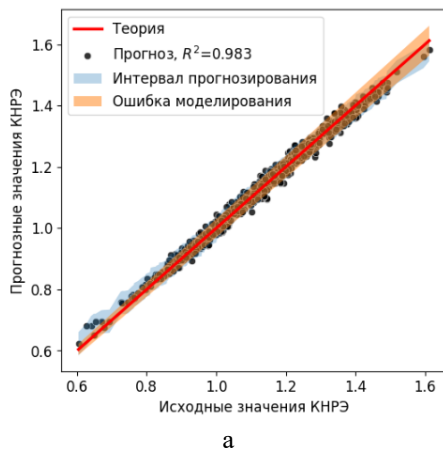


Рис. 3. Тестирование GBR-модели с L2-регуляризацией: а – сходимость тестовых и прогнозных значений; б – прогноз на случайной выборке

IV. ПРОЕКТИРОВАНИЕ НЕЙРОСЕТЕВЫХ АРХИТЕКТУР ДЛЯ МНОГОЗАДАЧНОГО И ОСТАТОЧНОГО ОБУЧЕНИЯ

Центральной задачей исследования является разработка универсальной нейросетевой архитектуры, способной переносить «знания», полученные на больших массивах простых данных, на задачи с высокой степенью детализации.

Для реализации перехода от упрощенной к детальной геометрии ТВС была спроектирована искусственная нейронная сеть (ИНС) типа многослойный перцептрон с архитектурой многозадачного обучения (рис. 4).




Рис. 4. Архитектура ИНС для многозадачного обучения (MLP_MTL)

Особенность данной структуры заключается в наличии общих скрытых слоев, которые обучаются на большом исходном массиве (более 2500 примеров) упрощенной геометрии, и индивидуальных «выходов» для специфических задач (рис. 5). Оптимизация весов проводится по взвешенной функции потерь (2)

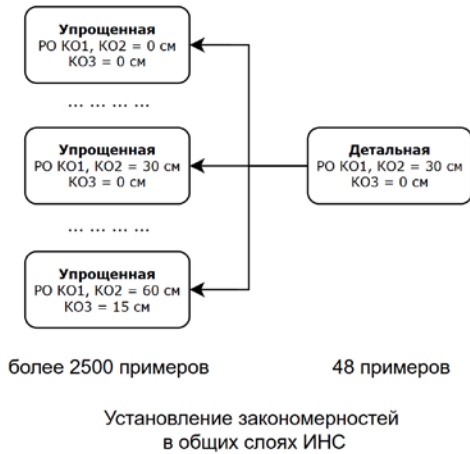


Рис. 5. Общая схема использования массивов упрощенной и детальной геометрий для обучения ИНС

$$\min_{\theta} L_{tot} = \min_{\theta} \sum_t^T \omega_t L_t(y, \hat{f}(x, \theta)), \quad (2)$$

где: L – функция потерь; ω – взвешивающий коэффициент; T – количество задач.

Результаты тестирования показали, что использование общего массива упрощенной геометрии позволяет повысить точность прогноза для детальной модели до $R^2 \approx 0,87$, в то время как классическая ИНС на малых данных детальной геометрии (48 примеров) достигает лишь $R^2 \approx 0,72$ [5–6].

Несмотря на эффективность использования взвешенной функции для ряда топливных ячеек, в целом по активной зоне присутствует повышенная погрешность (CAO выше на 30% по сравнению с упрощенной геометрией).

Для её минимизации был предложен подход обучения на остатках (Residual Learning). Архитектура (рис. 4) была дополнена Residual-блоком (рис. 6), который обучается предсказывать не абсолютные значения, а разницу (остаток) между детальным и упрощенным распределением (3) при сохранении общих весовых значений исходной модели MLP_MTL.

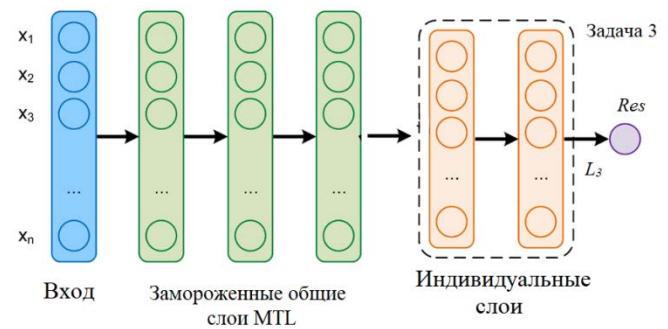


Рис. 6. Residual-блок для MLP_MTL-модели

$$\min_{\theta} \sum L(y^D - y^Y, \hat{f}(x, \theta)^D - \hat{f}(x, \theta)^Y),$$

$$\min_{\theta} \sum L(res, \widehat{res}), \quad (3)$$

$$\hat{f}(x, \theta)^D = \widehat{res} + \hat{f}(x, \theta)^Y,$$

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

Комбинированная модель (MLP_MTL + Residual-блок) показала значительные темпы сходимости, достигая «плато» уже к 100-й итерации (рис. 7). Итоговая точность по всей активной зоне составила $R^2 \approx 0,93$, при CAO не более 0,037. Ошибка в центральных ячейках снизилась на 33% относительно базовой MTL-архитектуры. На рис. 8 приведены прогнозные возможности модели при оценке на тестовых массивах данных.

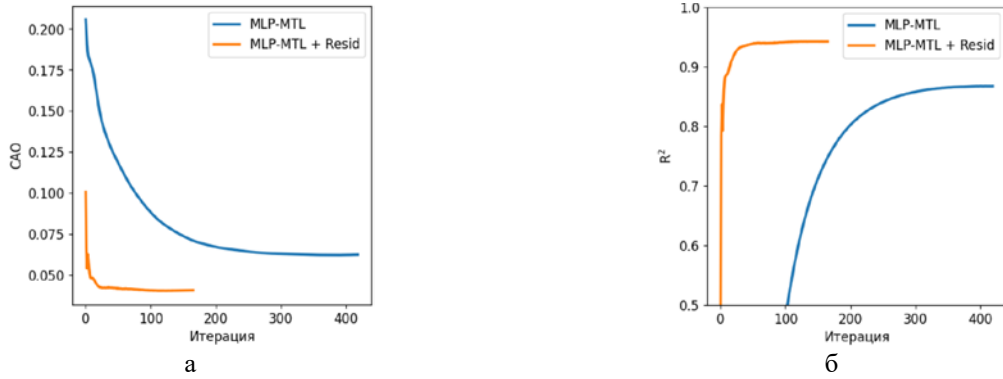


Рис. 7. Сходимость результатов на тестовой выборке для моделей MLP_MTL и MLP_MTL + Residual-блок

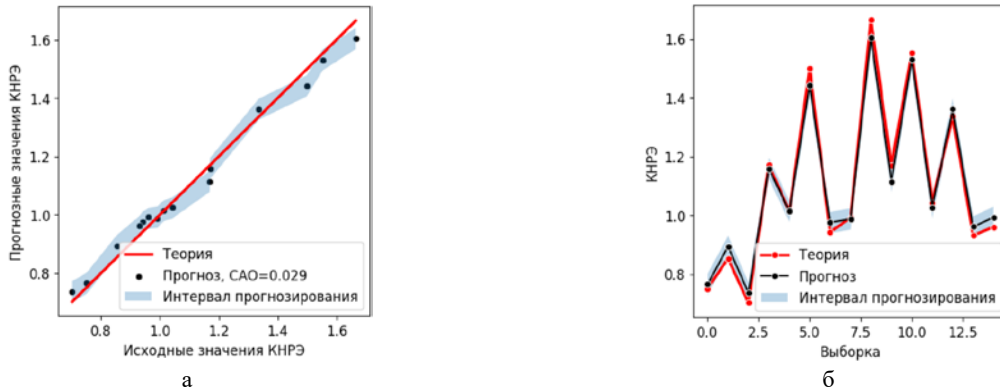


Рис. 8. Результаты модели MLP_MTL + Residual-блок для периферийной ячейки (7B) активной зоны: а – сходимость тестовых и прогнозных значений; б – прогноз на тестовой выборке

В табл. 2 приведено прямое сравнение прогнозных значений КНРЭ с результатами Монте-Карло моделирования в ПС MCU-PTR. Разброс значений по всем ячейкам удовлетворяет установленным интервалам

прогнозирования с вероятностью 95%, что подтверждает адекватность нейросетевого подхода для решения задач оперативного контроля реакторных установок

ТАБЛИЦА II. 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

V. ЗАКЛЮЧЕНИЕ

Разработанная нейросетевая модель на основе многозадачного и остаточного обучения показала свою эффективность в условиях вычислительных сложностей при проведении детализированного моделирования. Предложенная архитектура позволяет учитывать тонкие эффекты гетерогенности (рост КНРЭ до 47% вблизи ловушки) и может быть интегрирована в системы поддержки принятия при формировании топливных компоновок как элемент предиктивного анализа состояний активной зоны.

СПИСОК ЛИТЕРАТУРЫ

[1] 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

[2] I.A. Ushakov, V.V. Zukau, E.A. Nesterov, N.V. Smol'nikov, E.A. Shelikhova, E.S. Donyaeva. Substantiation of the Possibility to Obtain ¹⁷⁷Lu on the Average Flux Research Reactor IRT-T // Journal of Engineering Physics and Thermophysics. 2024. Vol. 97. № 6. P. 1478-1487.

[3] 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.

[4] 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.

[5] Briscoe E. Conceptual complexity and the bias/variance tradeoff / E. Briscoe, J. Feldman // Cognition. 2011. Vol. 118. № 1. P. 2-16

[6] Caruana R. Multitask Learning / R. Caruana // Machine Learning. 1997. T. 28. № 1. C. 41-75.