

ПРОГРАММНЫЙ КОМПЛЕКС ОЦЕНКИ ЗАПАСА РЕАКТИВНОСТИ РЕАКТОРА ВВР-ц

И.П. Белявцев, С.О. Старков

*Обнинский институт атомной энергетики НИЯУ «МИФИ»
249033, Калужская обл., г. Обнинск, Студгородок, 1*



Запас реактивности реактора ВВР-ц [1] можно рассчитать с помощью прецизионной модели реактора. Прецизионная модель, основанная на методе Монте-Карло [2], мало пригодна для оперативных расчетов. Представлена работа по созданию программного комплекса предварительной оценки запаса реактивности реактора ВВР-ц.

Обоснована возможность применения искусственной нейронной сети для построения аппроксимации запаса реактивности реактора по состоянию активной зоны. Проведены вычислительные эксперименты по обучению искусственной нейронной сети на данных прецизионной модели и на измеренных данных реального реактора. По итогам вычислительных экспериментов максимальная относительная ошибка аппроксимации $\Delta k/k$ от глубины выгорания составила 3,13 и 3,56% соответственно. Среднее время расчета – 100 мс.

В ходе вычислительных экспериментов была построена архитектура искусственной нейронной сети. Данная архитектура стала основой для построения программного комплекса оценки запаса реактивности реактора ВВР-ц – REST API веб-приложения, имеющего удобный пользовательский интерфейс для ввода конфигурации активной зоны. Есть возможность дополнить обучающую выборку новыми измерениями и доучить искусственную нейронную сеть.

Программный комплекс для оценки запаса реактивности готов для тестирования персоналом реактора ВВР-ц и использования его в виде компонента системы автоматического планирования перезагрузки реактора. С незначительными изменениями комплекс можно применять для реакторных установок других типов.

Ключевые слова: реактор ВВР-ц, запас реактивности, искусственные нейронные сети, программный комплекс, обобщенная аппроксимационная теорема.

ПОСТАНОВКА ЗАДАЧИ

В г. Обнинске Калужской области на базе филиала АО «НИФХИ им. Л.Я. Карпова» с 1964 г. находится в эксплуатации экспериментальная ядерная установка ВВР-ц – гетерогенный водо-водяной исследовательский реактор, специализированный для проведения широкого круга исследовательских работ в области радиационной химии, структурных и материаловедческих исследований, активационного анализа, нейтронного легирования полупроводников и т.д. [1]. С 1980 г. на базе реактора действует производство радионуклидов медицинского назначения, а также радиофармпрепаратов на их основе. В связи с успешностью развития данного направления и удобным географичес-

© И.П. Белявцев, С.О. Старков, 2018

ким положением в 1986 г. было принято решение о реконструкции реактора [2].

В связи с необходимостью улучшения параметров реактора и повышения эффективности наработки радионуклидов (^{99}Mo , ^{131}I и др.) в 2011 г. была проведена работа по созданию прецизионной нейтронно-физической расчетной модели активной зоны, отражателя реактора и органов СУЗ. При моделировании в полном объеме учитываются геометрия всех твэлов (топливо, оболочка, водяной зазор с соответствующими температурами), изменение изотопного состава топлива в зависимости от выгорания, геометрия и состав органов СУЗ, отражателей, экспериментальных каналов, конструкций. Полученная прецизионная модель была верифицирована для расчета запаса реактивности реактора [2].

Прецизионная модель основана на методе Монте-Карло, что позволяет добиться большой точности моделирования физических процессов активной зоны реактора. Однако данный подход требует большого количества машинного времени для проведения вычислительных экспериментов, например, расчет запаса реактивности для одной конфигурации активной зоны занимает около восьми часов.

Кампания реактора ВВР-ц составляет 100 часов в неделю с последующей остановкой для расхолаживания, перегрузки топлива, мишеней и других технологических операций [3]. При такой довольно короткой кампании использование прецизионной модели для проведения оперативных расчетов довольно затруднительно: при полной утилизации одной вычислительной системы можно сделать не более 12-ти расчетов в течение одной кампании. Таким образом, появляется задача по созданию программного комплекса для оценки запаса реактивности реактора ВВР-ц. Данный программный комплекс должен помочь научно-исследовательскому персоналу реактора в проведении предварительных расчетов запаса реактивности. К программному обеспечению предъявляется требование по кратному увеличению производительности расчета при сохранении достаточного уровня точности. Основная задача программного комплекса сводится к аппроксимации запаса реактивности реактора в зависимости от выгорания топлива и положения органов СУЗ.

ПРИМЕНЕНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ АППРОКСИМАЦИИ ЗАПАСА РЕАКТИВНОСТИ

В общем виде искусственными нейронными сетями (ИНС) называется подход к построению вычислительных алгоритмов и устройств, основанный на подобию биологических нейронов [4]. В рамках данной работы будем рассматривать искусственные нейронные сети как семейство алгоритмов для обработки информации.

Искусственный нейрон (формальный нейрон) – это элементарная вычислительная ячейка искусственной нейронной сети. Каждый искусственный нейрон получает вектор входных сигналов $\mathbf{x} = (x_0, x_1, \dots, x_n)$, для которого вычисляется взвешенная сумма. Затем от этой взвешенной суммы вычисляется значение функции активации φ :

$$n(\mathbf{x}) = \varphi\left(\sum_{i=0}^n w_i x_i + b\right),$$

где \mathbf{w} – весовой вектор; b – смещение.

Множество искусственных нейронов, получающих на вход единый вектор входных сигналов, называется полносвязным нейронным слоем. Последовательность нейронных слоев, в которой вектор выходных сигналов предыдущего слоя является вводным вектором последующего слоя, называется многослойным персептроном.

Все веса в многослойном персептроне инициализируются случайными малыми значениями. В такой конфигурации персептрон производит шум в ответ на любой входной вектор. Для настройки персептрона на выполнение заданной функции про-

изводится итеративный процесс обучения. Процесс обучения состоит в последовательном предъявлении на вход нейронной сети вектора из обучающего набора данных, получении результата на выходе нейронной сети, сравнении полученного выхода с ожидаемым выходом и корректировки весов для уменьшения полученной разницы. Одним из наиболее часто используемых алгоритмов для обучения является градиентный спуск [5].

Обоснуем возможность использования искусственной нейронной сети для построения аппроксимации. Для построения аппроксимации применима обобщенная аппроксимационная теорема. В соответствии с этой теоремой можно получить сколь угодно точное приближение любой непрерывной функции многих переменных, используя операции сложения и умножения на число, суперпозицию функций, линейные функции, а также одну произвольную непрерывную нелинейную функцию одной переменной [6]. Поскольку указанные операции полностью реализуются искусственной нейронной сетью с одним нелинейным формальным нейроном, то допустимо применять искусственную нейронную сеть для построения требуемой аппроксимации.

Для подтверждения возможности аппроксимации запаса реактивности с помощью ИНС было проведено два вычислительных эксперимента. В первом эксперименте искусственная нейронная сеть была обучена на данных, рассчитанных с помощью прецизионной модели. Во втором эксперименте искусственная нейронная сеть обучалась на реальных данных кампаний реактора ВВР-ц.

АППРОКСИМАЦИЯ МОДЕЛЬНЫХ ДАННЫХ

Для проведения эксперимента по аппроксимации модельных данных искусственной нейронной сетью формировался набор данных. С помощью прецизионной модели были проведены вычислительные эксперименты для 34-х различных конфигураций реактора (выгорание ТВС, положения СУЗ) и для каждой конфигурации получено значение запаса реактивности. Из полученного набора данных была сформирована обучающая выборка (25 конфигураций) и тестовая выборка (9 конфигураций). При конечной верификации использовались все 34 конфигурации активной зоны.

Для проведения эксперимента была создана трехслойная искусственная нейронная сеть. Входной слой состоит из 50-ти формальных нейронов с функцией активации ReLu:

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

Скрытый слой состоит из 10-ти формальных нейронов с функцией активации ReLu. Выходной слой состоит из одного формального нейрона с логистической функцией активации

$$f(x) = (1 + e^{-x})^{-1}.$$

Для обучения искусственной нейронной сети было проведено 50000 эпох обучения. Проводилось обучение методом обратного распространения ошибки по среднеквадратичной ошибке на обучающей выборке. Через каждые 100 эпох проводилась оценка среднеквадратичной ошибки на тестовой выборке. В течение всего процесса обучения ошибка сходилась к нулю без расхождения.

После завершения процесса обучения была проведена верификация ИНС на модельных данных. На рисунке 1 приведены полные результаты сравнения прецизионных расчетов запаса реактивности с результатами работы ИНС. Обобщенные результаты верификации:

- средняя абсолютная ошибка аппроксимации – 0,0405;
- максимальная абсолютная ошибка аппроксимации – 0,1029;
- средняя относительная ошибка аппроксимации – 1,21%;
- максимальная относительная ошибка аппроксимации – 3,13%.

Среднее время расчета запаса реактивности с помощью искусственной нейронной сети составляет 100 мс [7].




Рис. 1. График верификации работы искусственной нейронной сети, обученной на модельных данных (по оси абсцисс отложены номера измерений в вариационной выборке, по оси ординат – значение запаса реактивности, % $\Delta k/k$)

АППРОКСИМАЦИЯ ИЗМЕРЕННЫХ ДАННЫХ

Для проведения эксперимента по аппроксимации измеренных данных для обучения были взяты данные 24-х реальных кампаний реактора. Данные были разбиты на два набора: обучающая выборка (18 кампаний) и тестовая (6 кампаний). Для валидации обученной ИНС использовались данные всех 24-х кампаний.

Архитектура искусственной нейронной сети идентична архитектуре в первом эксперименте. Для обучения ИНС было проведено 50000 эпох обучения. Обучение также проводилось методом обратного распространения ошибки по среднеквадратичной ошибке на обучающей выборке. Через каждые 100 эпох выполнялась оценка среднеквадратичной ошибки на тестовой выборке. В течение всего процесса обучения ошибка сходилась к нулю без расхождения.

После завершения процесса обучения была проведена валидация ИНС на измеренных данных. На рисунке 2 приведены полные результаты сравнения измеренного запаса реактивности с результатами работы ИНС. Обобщенные результаты валидации:

- средняя абсолютная ошибка аппроксимации – 0,0412;
- максимальная абсолютная ошибка аппроксимации – 0,1159;
- средняя относительная ошибка аппроксимации – 1,26%;
- максимальная относительная ошибка аппроксимации – 3,56%.

Среднее время расчета запаса реактивности с помощью искусственной нейронной сети составляет 100 мс.

В рамках описанных вычислительных экспериментов было показано, что полученные нейросети реализуют корректную аппроксимацию, обладают высокими точностью и скоростью работы [7].




Рис. 2. График валидации работы искусственной нейронной сети, обученной на измеренных данных (по оси абсцисс отложены номера измерений в вариационной выборке, по оси ординат – значение запаса реактивности, % $\Delta k/k$)

ПРОГРАММНЫЙ КОМПЛЕКС ОЦЕНКИ ЗАПАСА РЕАКТИВНОСТИ РЕАКТОРА ВВР-Ц

На основании конечного числа прецизионных расчетов либо изменений с помощью искусственной нейронной сети оказалась возможной программная реализация процедуры аппроксимации оценки запаса реактивности реактора ВВР-ц. Для конфигураций активной зоны реактора в рамках обучающей выборки можно получить быструю и достаточно точную оценку запаса реактивности.

Следующий шаг – обеспечение возможности использования искусственных нейронных сетей для предварительных расчетов запаса реактивности. Для решения этой задачи потребовалась разработка программного комплекса оценки запаса реактивности реактора ВВР-ц.

Программный комплекс оценки запаса реактивности должен обеспечивать выполнение следующих требований:

- пополнять обучающую выборку для искусственной нейронной сети;
- работать в режимах обучения и использования обученной нейронной сети;
- иметь удобный и интуитивно понятный пользовательский интерфейс;
- обладать легкостью установки и эксплуатации.

Разработанный программный комплекс состоит из следующих структурных элементов:

- искусственная нейронная сеть;
- хранилище данных для обучения;
- REST API для обмена данными;
- пользовательский интерфейс.

Рассмотрим кратко эти элементы.

В качестве основы для построения искусственной нейронной сети использован фреймворк TensorFlow [8 – 10], который строит и исполняет граф вычислений в гетерогенных вычислительных системах, имеет богатую библиотеку примитивов для построения искусственных нейронных сетей и обеспечивает эффективное использование доступных вычислительных сред.

С помощью примитива DNNRegressor из библиотеки TensorFlow создана искусственная нейронная сеть. Входной слой сети – 50 формальных нейронов с функцией активации ReLu, скрытый слой – 10 формальных нейронов с функцией активации ReLu, выход-

ной слой – один формальный нейрон с логистической функцией активации. Таким образом, структура нейронной сети полностью повторяет архитектуру сети, использованную в вычислительных экспериментах.




Рис. 3. Интерфейс программного комплекса оценки запаса реактивности

Примитив DNNRegressor может функционировать в режимах обучения, оценки и предсказания.

Для обучения сети DNNRegressor применяет режимы обучения и оценки, а для использования ИНС – режим предсказания. Предварительно обученный примитив DNNRegressor сохраняется в файле tfdata, где содержатся описание графа предсказания (Inference) и все весовые коэффициенты формальных нейронов.

Для хранения обучающих данных используются файлы формата Comma-separated Values (CSV). Каждая запись представляет собой строку, в которую последовательно записаны проценты выгорания каждой ТВС, положения СУЗ, а также значение запаса реактивности при данной конфигурации активной зоны. Для проведения процедуры обучения данные из CSV-файлов загружаются в память в виде массивов NumPy.

Для обеспечения взаимодействия с пользователями программного комплекса с помощью библиотеки VueJs реализован веб-интерфейс управления [11 – 13], представляющий собой упрощенный вид картограммы реактора. В каждой из ТВС можно указать процент выгорания, а для каждого органа СУЗ – положение (рис. 3). В зависимости от выбранного режима работы будет либо произведена оценка запаса критичности реактора в данной конфигурации, либо добавлено еще одно значение в обучающую выборку. Для обеспечения связи между частями программного комплекта с помощью библиотеки Flask [14 – 16] реализован программный интерфейс приложения передачи состояния представления (REST API) [17, 18].

ВЫВОДЫ И ПЕРСПЕКТИВЫ

Рассмотрена возможность аппроксимации запаса реактивности реактора с помощью полносвязной искусственной нейронной сети в качестве предварительных расчетов; обучены две искусственные нейронные сети на разных наборах данных (на модельных, полученных с помощью прецизионной модели реактора, и на измеренных данных реальных кампаний). Показано, что обе аппроксимации обладают достаточной точностью для проведения предварительных расчетов запаса реактивности. По итогам вычислительных экспериментов максимальная относительная ошибка аппроксимации составила 3,13 и 3,56% соответственно.

На основе обученных искусственных нейронных сетей создан программный комплекс оценки запаса реактивности реактора ВВР-ц, позволяющий в удобной и наглядной форме получить предсказанное нейронной сетью значение запаса реактивности, а также пополнить обучающую выборку новыми данными для обучения.

Программный комплекс для оценки запаса реактивности готов для тестирования персоналом реактора ВВР-ц. Параллельно с тестированием в комплекс можно внести ряд изменений, повышающих удобство и безопасность эксплуатации: шифрование данных в обучающей выборке; авторизацию, аутентификацию и аккаунтинг пользователей; возможность ручного редактирования обучающей выборки.

Предполагается использование данного программного комплекса в виде компонента системы автоматического планирования перезагрузки реактора. С незначительными изменениями комплекс можно применять для реакторных установок других типов.

Литература

1. Кочнов О.Ю., Лукин Н.Д., Аверин Л.В. Реактор ВВР-ц: опыт эксплуатации и перспективы развития. // Ядерная и радиационная безопасность. – 2008. – №1. – С. 18-25.
2. Колесов В.В., Кочнов О.Ю., Волков Ю.В., Украинцев В.Ф., Фомин Р.И. Создание прецизионной модели реактора ВВР-ц для последующей оптимизации его конструкции и наработки ^{99}Mo и других радионуклидов. // Известия высших учебных заведений. Ядерная энергетика. – 2011. – №4. – С. 129-133.
3. Кочнов О.Ю., Колесов В.В., Фомин Р.И., Жердев Г.М. Оценка увеличения производства ^{131}I при использовании теллурических мишеней усовершенствованной конструкции на реакторе ВВР-ц. // Известия высших учебных заведений. Ядерная энергетика. – 2014. – №4. – С. 102-110.
4. Хайкин С. Нейронные сети. Полный курс. – М.: Издательский дом «Вильямс». – 2006. – 1104 с.
5. Филатова Т.В. Применение нейронных сетей для аппроксимации данных // Вестник Томского государственного университета. – 2004. – №284. – С. 121–125.
6. Горбань А. Н. Обобщенная аппроксимационная теорема и вычислительные возможности нейронных сетей. // Сибирский журнал вычислительной математики. – 1998. – Т. 1. – №1. – С. 12-24.

7. *Belyavtsev I., Legchikov D., Starkov S., Kolesov V., Nikulin E.* Approximation of the criticality margin of WWR-c reactor using artificial neuron networks // Journal of Physics: Conference Series. – 2018. – Т. 945. – PP. 012–031.
8. *Abadi M., Barham P., Chen J., Chen Zh., Davis A., Dean J., Devin M., Ghemawat S., Irving G., Isard M., Kudlur M., Levenberg J., Monga R., Moore Sh., Murray D., Steiner B., Tucker P., Vasudevan V., Warden P., Wicke M., Yu Yu., Zheng X.* TensorFlow: Large-scale machine learning on heterogeneous systems. – 2015. Электронный ресурс: <https://www.tensorflow.org/about/bib> (дата обращения 2.05.2018)
9. *Zaccane G.* Getting Started with TensorFlow. – Packt Publishing – 2016. – 180 p.
10. *Lieder I., Resheff Y., Hope T.* Learning TensorFlow. A Guide to Building Deep Learning Systems. – O'Reilly Media. – 2017. – 242 p.
11. *You E.* VueJs. Электронный ресурс: <https://vuejs.org/v2/guide/> (дата обращения 2.05.2018).
12. *Filipova O.* Learning Vue.js 2. Learn how to build amazing and complex reactive web applications easily with Vue.js. – Packt Publishing. – 2016. – 334 p.
13. *Street M.* Vue.js 2.x by Example. – Packt Publishing. – 2017. – 412 p.
14. *Ronacher A.* Flask. Электронный ресурс: <http://flask.pocoo.org/> (дата обращения 2.05.2018).
15. *Grinberg M.* Flask Web Development, 2nd Edition. – O'Reilly Media. – 2018. – 316 p.
16. *Dwyer G.* Flask by Example. – Packt Publishing. – 2016. – 276 p.
17. *Masse M.* REST API Design Rulebook. – O'Reilly Media. – 2011. – 116 p.
18. *Richardson L., Ruby S.* RESTful Web Services. – O'Reilly Media. – 2008. – 448 p.

Поступила в редакцию 24.05.2017 г.

Авторы

Белявцев Иван Павлович, аспирант
E-mail: djbelyak@gmail.com

Старков Сергей Олегович, профессор, доктор физ.-мат. наук
E-mail: sergeystarkov56@mail.ru

UDC 004.89

CRITICALITY MARGIN EVALUATION SOFTWARE FOR WWR-c REACTOR

Belyavtsev I.P., Starkov S.O.

Obninsk Institute for Nuclear Power Engineering, NRNU «MEPhI»
1 Studgorodok, Obninsk, Kaluga reg., 1249033 Russia

ABSTRACT

The criticality margin of a WWR-c reactor can be calculated using a precision reactor model. However, due to the high computing time consumption (approximately eight hours of calculations per one state of the reactor core), it would be rather difficult to use this model for making operational criticality margin evaluations. This problem has determined the purpose of this work, namely, to create a software package for preliminary evaluations of the WWR-c reactor criticality margin.

The research has confirmed the possibility of using an artificial neural network to approximate the criticality margin based on the reactor core state. A number of computational experiments were conducted on training the artificial neural network, using the precision model data and real reactor measured data. According to the results of these computational experiments, the maximum relative approximation error was found to be 3.13 and 3.56%, respectively. The mean computation time was 100 ms.

Based on these experiments, it became possible to develop a software package for evaluating the WWR-c reactor criticality margin – REST API based web-application – which has a convenient user interface for inputting the core configurations and

obtaining evaluations. Besides that, it is also possible to supplement the training sample with new measurements and to finish training the artificial neural network.

The criticality margin evaluation software is ready to be tested by the WWR-c reactor personnel as well as to be used as a component of the automated reactor refueling system. In future, with some modifications, this software package can be used for reactor plants of other types.

Key words: WWR-c reactor, criticality margin, artificial neural networks, software package, generalized approximation theorem.

REFERENCES

1. Kochnov O.Yu., Lukin N.D, Averin L.V. WWR-c reactor: exploitation experience and development prospects. *Yadernaya i radiatsionnaya bezopasnost'*, 2008, no.1, pp. 18-25 (in Russian).
2. Kolesov V.V., Kochnov O.Yu., Volkov Yu.V., Ukraintsev V.F., Fomin R.V. Creation of the WWR-c Reactor Precision Model for Its Construction Optimisation and Following Optimisation of the ^{99}Mo and Other Radioisotope Productivity. *Izvestia vysshikh uchebnykh zavedenij. Yadernaya energetika*. 2011, no. 4, pp. 129-133 (in Russian).
3. Kochnov O.Yu. Kolesov V.V. Fomin R.V. Jerdev G.M. Assessment of the increasing in ^{131}I production due to improved tellurium target in the WWR-C reactor core. *Izvestia vysshikh uchebnykh zavedenij. Yadernaya energetika*. 2014, no.4, pp. 102-110 (in Russian).
4. Simon Haykin. *Neural networks. A Comprehensive Foundation*. Second Edition. Prentice Hall, Inc., 1999. 1104 p.
5. Filatova T.V. Application of neural networks for data approximation. *Vestnik Tomskogo gosudarstvennogo universiteta*. 2004, no.284, pp. 121-125 (in Russian).
6. Gorban' A.N. Generalized approximation theorem and computational capabilities of neural networks. *Sibirskij zhurnal vychislitel'noy matematiki*. 1998, v. 1, no. 1, pp. 12-24 (in Russian).
7. Belyavtsev I., Legchikov D., Starkov S., Kolesov V., Nikulin E. Approximation of the criticality margin of WWR-c reactor using artificial neuron networks. *Journal of Physics: Conference Series*. 2018, v. 945, pp. 012-031.
8. Abadi M., Barham P., Chen J., Chen Zh., Davis A., Dean J., Devin M., Ghemawat S., Irving G., Isard M., Kudlur M., Levenberg J., Monga R., Moore Sh., Murray D., Steiner B., Tucker P., Vasudevan V., Warden P., Wicke M., Yu Yu., Zheng X. TensorFlow: Large-scale machine learning on heterogeneous systems. – 2015. Available at: <https://www.tensorflow.org/about/bib> (accessed May 2, 2018).
9. Zaccane G. *Getting Started with TensorFlow*. Packt Publishing, 2016. 180 p.
10. Lieder I., Resheff Y., Hope T. *Learning TensorFlow. A Guide to Building Deep Learning Systems*. O'Reilly Media, 2017, 242 p.
11. You E. VueJs. Available at: <https://vuejs.org/v2/guide/> (accessed May 2, 2018).
12. Filipova O. *Learning Vue.js 2. Learn how to build amazing and complex reactive web applications easily with Vue.js*. Packt Publishing, 2016. 334 p.
13. Street M. *Vue.js 2.x by Example*. Packt Publishing, 2017. 412 p.
14. Ronacher A. Flask. Available at: <http://flask.pocoo.org/> (accessed May 2, 2018).
15. Grinberg M. *Flask Web Development, 2nd Edition*. O'Reilly Media, 2018. 316 p.
16. Dwyer G. *Flask by Example*. Packt Publishing, 2016. 276 p.
17. Masse M. *REST API Design Rulebook*. O'Reilly Media, 2011. 116 p.
18. Richardson L., Ruby S. *RESTful Web Services*. O'Reilly Media, 2008. 448 p.

Authors

Belyavtsev Ivan Pavlovich, PhD Student

E-mail: djbelyak@gmail.com

Starkov Sergey Olegovich, Professor, Dr. Sci. (Phys.-Math.)

E-mail: sergeystarkov56@mail.ru