

ИСПОЛЬЗОВАНИЕ РЕКУРРЕНТНОЙ НЕЙРОННОЙ СЕТИ ДЛЯ РЕШЕНИЯ ОБРАТНОЙ ЗАДАЧИ ТЕПЛОПРОВОДНОСТИ ПРИМЕНИТЕЛЬНО К РАСЧЕТУ ТЕМПЕРАТУРЫ ОБОРУДОВАНИЯ РУ С ВВЭР

Дерябин И.А., Королев В.В., Сорокин Г.С.

АО ОКБ «ГИДРОПРЕСС»,
142103, Московская обл., г. Подольск, ул. Орджоникидзе, д. 21



Необходимость в решении нестационарных граничных обратных задач теплопроводности (ОЗТ) как инструмента, позволяющего получить недостающую информацию о рассматриваемом объекте, может возникать как при обработке результатов экспериментов, так и при термометрировании, а в некоторых случаях и при конструировании. Применительно к АЭС типа ВВЭР использование результатов решения ОЗТ может быть связано с обработкой данных при проведении пуско-наладочных измерений или контролем ресурса оборудования с помощью термпар во время эксплуатации станции. В работе предложена и описана методика расчета граничной обратной задачи теплопроводности с помощью рекуррентной нейронной сети типа NARX. Неизвестные значения весов и отступов вычисляются с помощью алгоритма градиентного спуска Левенберга – Марквардта в процессе обучения на специально созданном наборе данных, полученном при расчете прямой задачи теплопроводности на серии случайно сгенерированных температурных ударов. На ряде примеров показана применимость методики для решения линейных и нелинейных задач теплопроводности. Рассмотрены вопросы, связанные с параметрами нейронной сети, такими как отступы и число предыдущих рассматриваемых шагов по времени. Отдельно рассмотрена двухмерная задача, в которой показано, что внесение дополнительной информации во входные данные позволяет значительно снизить погрешность получаемых результатов.

Ключевые слова: температура, обратная задача теплопроводности, рекуррентная нейронная сеть, РУ с ВВЭР.

Для цитирования: *Дерябин И.А., Королев В.В., Сорокин Г.С.* Использование рекуррентной нейронной сети для решения обратной задачи теплопроводности применительно к расчету температуры оборудования РУ с ВВЭР. // Известия вузов. Ядерная энергетика. – 2024. – № 4. – С. 144–154.
DOI: <https://doi.org/10.26583/npe.2024.4.12>

© *Дерябин И.А., Королев В.В., Сорокин Г.С., 2024*

ПОСТАНОВКА ЗАДАЧИ

Одним из типов некорректной задачи теплопроводности является граничная задача, где искомым параметром является граничное условие на одной из поверхностей, ограничивающих заданную область. На других поверхностях граничное условие задано и может быть переопределено, а также дополнительно могут быть заданы значения температур в некоторых отдельных точках пространства. Данная задача является неустойчивой из-за отсутствия единственного решения и имеет большую чувствительность к входным данным.

При обработке результатов эксперимента или мониторинге теплового состояния конструкций, а также, в некоторых случаях, при конструировании, может возникать потребность в дополнительных данных, которые могут быть получены при решении нестационарных граничных обратных задач теплопроводности (ОЗТ). Для оборудования РУ с ВВЭР такой подход применим для осуществления контроля ресурса с помощью термпар во время всего жизненного цикла АЭС, а также в процессе обработки данных при проведении пуско-наладочных испытаний.

Необходимо отметить, что в работе будут рассматриваться задачи теплопроводности (материалы, диапазон изменения температур), в той или иной мере связанные с применением полученных результатов при термометрировании оборудования и трубопроводов АЭС типа ВВЭР.

В настоящее время существует множество методик решения ОЗТ [1–3], при этом подавляющее большинство из них связано с минимизацией функционала, определяющего расстояние в пространстве L_2 между заданной и неизвестной величиной итерационными методами или методом наименьших квадратов. Оптимизируются в общем случае параметры одной или множества функций. В зависимости от объекта исследования могут использоваться некоторые упрощения задачи, например, сведение геометрии к одномерной или самой задачи – к линейной постановке.

РАССМАТРИВАЕМАЯ НЕЙРОННАЯ СЕТЬ

Применение нейронных сетей для решения нестационарной задачи теплопроводности рассмотрено во многих работах [4–6], где наибольшее внимание уделяется многослойным сетям типа PINN. Получаемые решения с помощью данных сетей являются сильно чувствительными к входным данным, а сами сети имеют достаточно сложную структуру.

Рекуррентные нейронные сети типа ARX, LSTM в данный момент активно используются при обработке текстов, а также для прогнозирования показаний одних датчиков на основании показаний других. Главной особенностью рекуррентных нейронных сетей является способность передавать информацию с выходного слоя обратно на вход сети, что позволяет намного лучше описывать взаимозависимые временные ряды.

В данной работе рассматривается применение рекуррентной нейронной сети типа NARX [7, 8] для решения граничной обратной задачи теплопроводности. Нейронная сеть типа NARX является динамической сетью и в отличие от ближайшего родственника – сети ARX – имеет несколько предыдущих внешних сигналов на входе. На рисунке 1

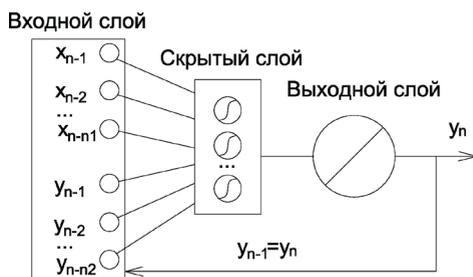


Рис. 1. Общий вид нейронной сети типа NARX

представлен общий вид такой сети, состоящей из n_1+n_2 входных сигналов во входном слое, произвольного числа нейронов в скрытом слое (с гиперболическим тангенсом в качестве функции активации) и одного выходного линейного нейрона в выходном слое.

Числа n_1 , n_2 , а также число нейронов в скрытом слое являются подбираемыми параметрами и для каждой рассматриваемой задачи они могут быть различными. Под входными сигналами x понимаются наборы данных, от которых напрямую зависит искомая величина y . В рассматриваемой граничной обратной задаче теплопроводности x – это неизвестные параметры, например, значения температур в любой точке рассматриваемого тела или значения граничных условий, которые могут быть получены путем непосредственного измерения температуры с помощью термометра. Соответственно под y понимаются значения неизвестных температур и граничных условий.

ПЛОСКАЯ ПЛАСТИНА. ЛИНЕЙНАЯ ЗАДАЧА

Большой интерес представляют граничные ОЗТ, где необходимо оценить тепловой поток на одной из границ по известным значениям температуры на другой или наоборот. Рассмотрим плоскую пластину толщиной h и с теплоизолированной наружной поверхностью (принимается, что тепловой поток равен нулю) с известным законом изменения температуры во времени на ней T_1 при неизвестной температуре на внутренней поверхности T_2 . При этом температура T_1 задана дискретно в моменты времени с равным интервалом Δt . С торцевых поверхностей тепловой поток отсутствует. Если другие дополнительные условия не накладываются, тогда, математически данная рекуррентная нейронная сеть в условиях такой задачи может быть записана как

$$T_2^n = f(T_1^{n-1}, T_1^{n-2} \dots T_1^{n-n_1}, T_2^{n-1}, T_2^{n-2} \dots T_2^{n-n_2}),$$

где T_2^n – значение температуры на n шаге по времени на внутренней поверхности пластины.

Таким образом, задавая первые n_1 и n_2 значения T_1 и T_2 соответственно, можно получить остальные значения T_2 на всем интересующем нас интервале времени. Неизвестные значения весов и отступов вычисляются с помощью алгоритма градиентного спуска Левенберга – Марквардта в процессе обучения на специально созданном нормированном наборе данных относительных температур, полученном при расчете прямой задачи теплопроводности на серии случайно сгенерированных температурных ударов. Решения прямых задач может быть получено как аналитически, так и численно, например, при помощи метода конечных элементов (МКЭ).

Поиск истинного значения неизвестной температуры в задачах подобного рода усложняется с уменьшением коэффициента теплопроводности и увеличением толщины пластины, что связано с эффектом температурного запаздывания. Для отслеживания этого явления в тестовом расчете рассмотрим две пластины толщиной 30 и 20 мм при двух различных температурных воздействиях на внутренней стороне:

- резкое изменение температуры T_2 с 0 до 100°C за 1 с (тест № 1);
- периодическое изменение температуры T_2 по закону синуса с амплитудой 50°C и периодом 100 с (тест № 2).

Коэффициент теплопроводности примем постоянным и равным $5 \cdot 10^{-6}$ м²/с, что соответствует распространенной в машиностроении стали 08X18H10T. Теплопроводность данной стали слабо меняется в широком температурном диапазоне [9], а значит, принятое допущение является оправданным.

В процессе обучения моделей было замечено, что небольшое смещение входных данных влево по временной шкале положительно сказывается на предиктивной способности моделей, что связано с эффектом температурного запаздывания. Несмотря на отсутствие физической обоснованности, смещение влево позволяет в некоторой мере синхронизировать моменты подъема и снижения температуры, что позволяет быстрее найти взаимосвязь между величинами. Это смещение, обозначим его $n3$, является, как $n1$ и $n2$, подбираемым путем оптимизации параметром нейронной сети.

После проведения процесса оптимизации параметров нейронной сети были получены результаты, представленные на рис. 2 на примере пластины толщиной 30 мм. Отметим, что в данном случае для корректной работы сети необходим всего один нейрон в скрытом слое. В таблице 1 приведены среднеквадратичные отклонения при различных смещениях параметров сети от оптимальных значений. Отклонение вычисляется как

$$RMSE = \sqrt{\frac{1}{N} \sum_i^N (\hat{T}_2^i - T_2^i)^2},$$

где в скобках стоит разница между предсказанным и истинным значением температуры в i момент времени, а N – общее число шагов по времени.

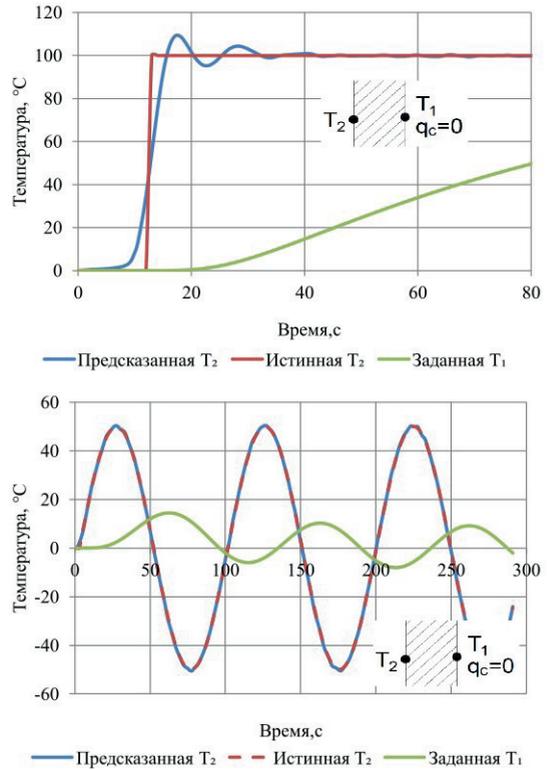


Рис. 2. Результаты для пластины толщиной 30 мм

Среднеквадратичные отклонения истинных значений температур от предсказанных, °С

Таблица 1

Толщина пластины	$h=30$ мм				$h=20$ мм			
	$n1=8$ $n2=8$ $n3=7$	$n1=8$ $n2=8$ $n3=6$	$n1=8$ $n2=2$ $n3=7$	$n1=2$ $n2=8$ $n3=7$	$n1=8$ $n2=8$ $n3=5$	$n1=8$ $n2=8$ $n3=4$	$n1=8$ $n2=2$ $n3=5$	$n1=2$ $n2=8$ $n3=5$
Отклонения в тесте № 1	4,06	4,25	4,08	26,43	2,67	2,99	2,68	4,15
Отклонения в тесте № 2	0,37	0,49	0,58	44,88	0,16	0,13	0,19	0,73

Дальнейшее снижение $n3$ приводит к неправильной работе нейронной сети и большим отклонениям. Существенное снижение параметра $n1$ до значения 2 приводит к аналогичным результатам, в то время, как изменение параметра $n2$ не оказывает существенного влияния на результат при данной постановке задачи. В целом, при значении $n3$ и $n1$ больше некоторых предельных значений наблюдаются стабильно хорошие показатели нейронной сети.

Видно, увеличение толщины пластины приводит к увеличению значений отклонения, а также к необходимости увеличивать значение $n3$, так как запаздывание отклика температуры на наружной поверхности увеличивается.

Для сравнения на рис. 3 приведены результаты расчета ОЗТ для пластины толщиной 30 мм методом функциональной аппроксимации, основанной на разложении неизвестной функции температуры в ряд, состоящий из 50-ти гармоник [3]. Среднеквадратичное отклонение составляет 5,75°C.

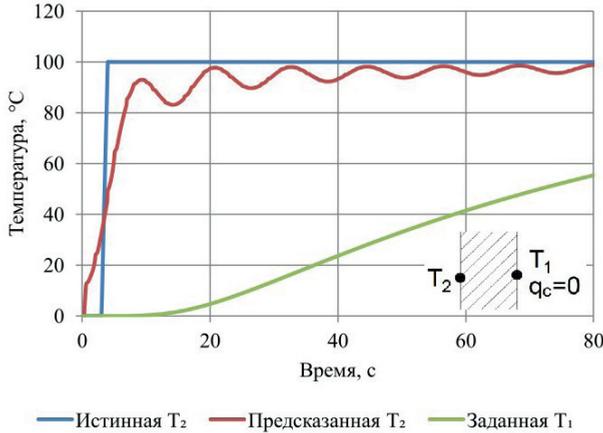


Рис. 3. Результаты решения ОЗТ методом функциональной аппроксимации

ПЛОСКАЯ ПЛАСТИНА. НЕЛИНЕЙНАЯ ЗАДАЧА

Рассмотрим аналогичную постановку задачи из предыдущей главы с той лишь разницей, что температуропроводность будет являться функцией температуры. Для этого заменим материал пластины на сталь 10ГН2МФА, у которой данное свойство меняется в диапазоне от $1,43 \cdot 10^{-5}$ м²/с при 20°C до $9,17 \cdot 10^{-6}$ м²/с при 400°C. Необходимо отметить, что в данном случае нет возможности рассматривать температуру в относительном виде и случайная тренировочная выборка формируется в абсолютных значениях температур.

Будем рассматривать только пластину толщиной 30 мм как наиболее сложный случай, и при двух различных температурных воздействиях на внутренней стороне:

- резкое изменение температуры T_2 с 100 до 200°C за 1 с (тест № 1);
- падение температуры T_2 с 350 до 20°C за 50 с (тест № 2).

Диапазон температур в тесте № 2 характерен для условий работы реакторной установки типа ВВЭР.

Оптимальными параметрами нейронной сети в данном случае являются $n1=3$, $n2=5$ и $n3=5$. Снижение параметров связано с увеличением температуропроводности материала по сравнению с предыдущим примером. Результаты, представлены на рис. 4. Среднеквадратическое отклонение составляет 4,57 и 5,93°C для теста № 1 и № 2 соответственно. Данные получены при одном нейроне в скрытом слое. Увеличение числа нейронов может заметно снизить погрешность расчета. Среднеквадратическое отклонение при расчете с пятью нейронами в скрытом слое составляет 3,46°C. Исследование таких сетей планируется в дальнейших работах по данной тематике.

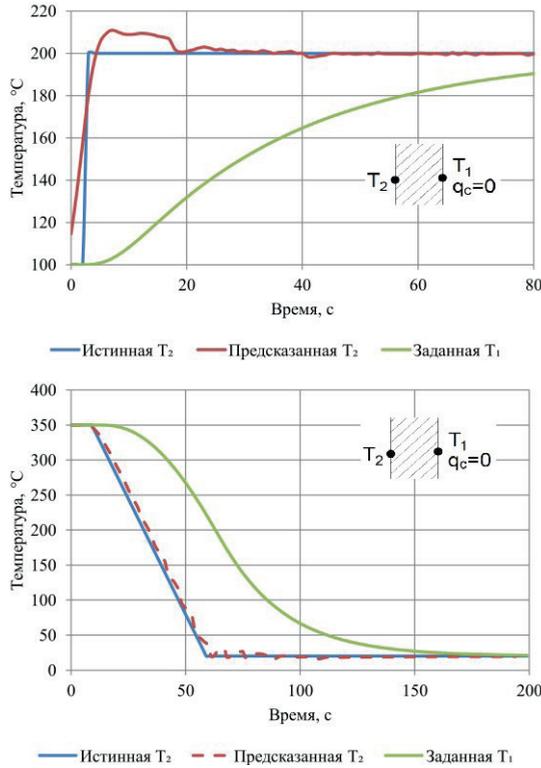


Рис. 4. Результаты расчета для плоской нелинейной задачи

ДВУМЕРНАЯ ЗАДАЧА

Представляют определенный интерес задачи, где неизвестной величиной является не граничное условие, а значение температуры в некоторой точке внутри тела. Рассмотрим плоскую пластину, представленную на рис. 5. Толщина пластины составляет $h_1=15$ мм и $h_2=30$ мм, а протяженность в вертикальном и горизонтальном направлениях не ограничена (для удобства на рис. 5 область показана в конечных размерах). На нижней и левой поверхностях – неизвестные заранее граничные условия (температура T_{in} , поток q или температура среды T_f с коэффициентом теплоотдачи) в зависимости от времени; остальные поверхности являются адиабатными. Пусть температуры в областях, расположенных вдали от угловой точки, а именно, T_1 и T_2 , заданы дискретно в моменты времени с равным интервалом $\Delta t=1$ с. Тем-

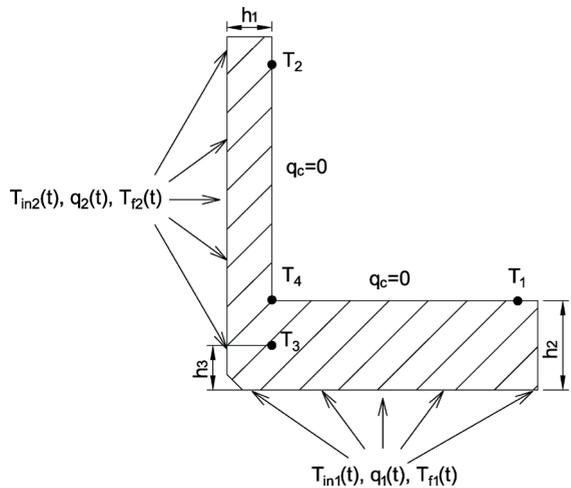


Рис. 5. Рассматриваемая двумерная расчетная область

пература в точке T_3 , расположенной на расстоянии $h_3 = 15$ мм от нижнего края, является неизвестным параметром.

В данном случае неизвестная величина может быть представлена как функция

$$T_3^n = f(T_1^{n-1}, T_1^{n-2} \dots T_1^{n-n1}, T_2^{n-1}, T_2^{n-2} \dots T_2^{n-n1}, T_3^{n-1}, T_3^{n-2} \dots T_3^{n-n2}).$$

Дополнительно рассмотрим, как влияет наличие данных по температуре в точке T_4 на результаты расчета.

Примем, что теплофизические свойства не зависят от температуры и соответствуют стали 08X18H10T с теплопроводностью $5 \cdot 10^{-6}$ м²/с.

Было рассмотрено два тестовых режима с граничными условиями 1 и 3 рода на внутренней поверхности. На рисунке 6 приведен пример зависимости T_{in1} и T_{in2} от времени вместе с температурами T_1 и T_2 . При задании граничного условия 3 рода T_{f1} и T_{f2} имеют аналогичный вид. Коэффициент теплоотдачи во втором тестовом режиме принят постоянным и равным 1000 Вт/(м²К) для обеих поверхностей. Такое температурное воздействие приводит к возникновению в окрестности точки T_3 двумерных температурных полей. Обучающий набор данных состоит из большого числа прямых задач теплопроводности, решенных с помощью МКЭ, в которых случайным образом происходят температурные воздействия на поверхности с граничным условием 1 рода. Расчеты производились при одном нейроне в скрытом слое и параметрах $n1 = 6$, $n2 = 3$, и $n3 = 7$. Необходимо отметить, что в данной задаче параметр $n2$ существенно влияет на результат, а его значение, равное 3, получено в результате вариативных расчетов.

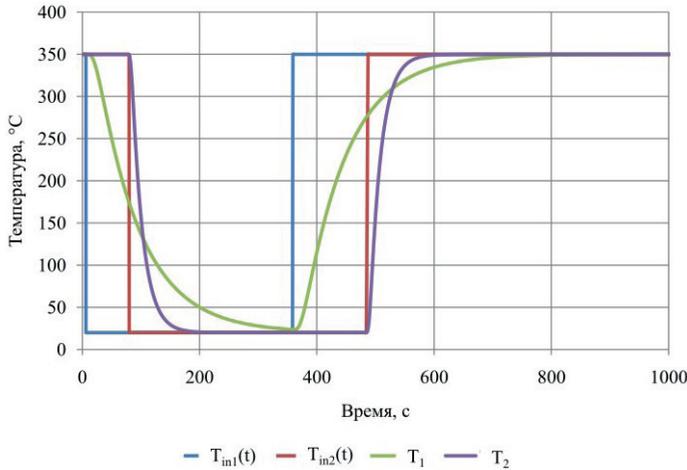


Рис. 6. Тестовый режим двумерной пластины

На рисунке 7 приведены результаты расчета при обучении с учетом температуры T_4 и без учета. Без обработки результатов видно, что вносимая дополнительная информация в виде дополнительной температурной точки положительно сказывается на результатах расчета. Таким образом, установка дополнительных температурных датчиков для термометрирования реальных сложных конструкций может в перспективе значительно снизить погрешность определения искомых значений температур. Среднеквадратическое отклонение без учета температуры T_4 и с учетом составляет 6,5 и 0,8°C для первого теста, а для второго – 7,5 и 2,8°C соответственно.

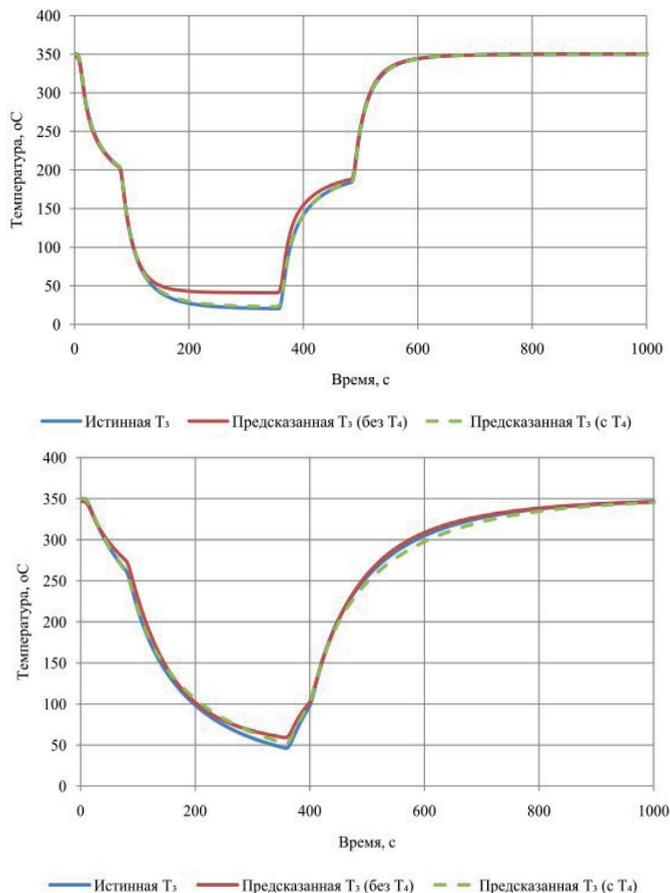


Рис. 7. Результаты расчета для двумерной пластины

ЗАКЛЮЧЕНИЕ

В статье рассмотрена методика решения граничной обратной задачи теплопроводности с помощью рекуррентной нейронной сети типа NARX. Приведен общий подход к использованию данного вида сети.

Структура применяемой в работе сети содержит один нейрон в скрытом слое, однако показано, что добавление дополнительных нейронов приводит к уменьшению погрешности расчета. Рассмотрение сети с несколькими нейронами в скрытом слое является предметом дальнейшего исследования. Неизвестные значения весов и отступов вычисляются с помощью алгоритма градиентного спуска Левенберга – Марквардта в процессе обучения на специально созданном нормированном наборе данных, полученном при расчете прямой задачи теплопроводности с помощью МКЭ на серии случайно сгенерированных температурных ударов.

Материалы, полученные в работе, в первую очередь направлены на применение в области конструирования и эксплуатации РУ типа ВВЭР. Исходя из этого представления были выбраны постановки тестовых задач, материалы конструкций и диапазоны температур. Основным преимуществом данного метода является отсутствие необходимости решения самого нестационарного уравнения теплопроводности в процессе вычисления

неизвестной температуры, что значительно ускоряет процесс вычисления и позволяет использовать подход в системах мониторинга в режиме реального времени.

Можно отметить следующие основные результаты работы:

- расчетные данные, полученные при решении ОЗТ, имеют хорошую точность для всех рассмотренных примеров;
- предсказанные значения могут существенно зависеть от макропараметров сети, которые должны подбираться индивидуально под каждый вид задачи, либо необходимо проводить обобщение похожего класса задач за счет единой оптимизации параметров;
- при смещении параметров сети вблизи оптимальных значений не происходит значительного изменения в точности предсказуемых неизвестных значений;
- для корректной работы нейронной сети при решении подобного класса задач необходимо вводить параметр $n3$, отвечающий за сдвиг входных данных по температуре;
- показано, что внесение дополнительной информации в исходные данные для обучения нейронной сети положительно влияет на ее получаемый результат.

Данная методика решения ОЗТ, основанная на рекуррентной нейронной сети типа NARX, имеет большой потенциал для применения как в программах, связанных с термометрированием АЭС типа ВВЭР, так и при проведениях различного рода температурных экспериментов; также существует возможность использования данной методики для решения задач определения непосредственно напряжений в элементах конструкций.

Литература

1. Алифанов О.М. Обратные задачи теплопроводности. М.: Машиностроение, 1988. – 280 с. ISBN 5-217-00134-8.
2. Богачев А.В., Дранченко Б.Н., Семишкин В.П., Беркович В.Я. Развитие системы САКОР-М. // Вопросы атомной науки и техники. Серия: Обеспечение безопасности АЭС. Научно-технический сборник: Выпуск № 15. Реакторные установки ВВЭР. – Подольск. – 2006.
3. Королев В.В. Методика обработки результатов контроля температур и давления в элементах оборудования реакторных установок. // Вопросы атомной науки и техники. Серия: Обеспечение безопасности АЭС. Научно-технический сборник: Выпуск 17. Реакторные установки ВВЭР. – Подольск. – 2007.
4. Deng S., Hwang Y. Applying neural networks to the solution of forward and inverse heat conduction problems. // International Journal of Heat and Mass Transfer. – 2006. – V. 49. – Iss. 25–26. – PP. 4732–4750. DOI: <https://doi.org/10.1016/j.ijheatmasstransfer.2006.06.009>
5. Васильев А.Н., Порубаев Ф.В., Тархов Д.А. Нейросетевые подходы к решению некорректных задач теплопереноса. // Научно-технические ведомости СПбГПУ. – 2011. – Вып. 1. – С. 133–142.
6. Zhili He, Futao Ni, Weiguo Wang, Jian Zhang. A physics-informed deep learning method for solving direct and inverse heat conduction problems of materials. // Materials today communications. – 2021. – V. 28. – 102719. DOI: <https://doi.org/10.1016/j.mtcomm.2021.102719>
7. Ruiz L.G.B., Cuéllar M.P., Calvo-Flores M.D., Jiménez M.D.C.P. An Application of Non-Linear Autoregressive Neural Networks to Predict Energy Consumption in Public Buildings. // Energies. – 2016. – V. 9. – 684. DOI: <https://doi.org/10.3390/en9090684>
8. Jose Maria P.Menezes Jr, Guilherme A. Barreto. Long-term time series prediction with NARX network: An empirical evaluation. // Neurocomputing. – 2008. – V. 71. – Iss. 16–18. – PP. 3335–3343. DOI: <https://doi.org/10.1016/j.neucom.2008.01.030>
9. Зубченко А.С., Колосков М.М., Каширский Ю.В. Марочник сталей и сплавов. – М.: Машиностроение, 2003. – 784 с.

Поступила в редакцию 24.03.2024

Авторы

Дерябин Иван Андреевич, ведущий инженер-конструктор,

E-mail: Deryabin_IA@grpress.podolsk.ru;

Королев Владимир Васильевич, ведущий инженер-конструктор, к.ф.-м.н.,

Сорокин Георгий Сергеевич, начальник группы.

UDC 504.064.3:517.95:004.032.26

Using a Recurrent Neural Network for Solving Inverse Heat Conduction Problem with Application to Calculating the Temperature of Equipment of VVER-Based NPPs

Deryabin I.A., Korolev V.V., Sorokin G.S.

OKB Hidropress JSC,

21 Ordzhonikidze St., 142103 Podolsk, Moscow reg., Russia

Abstract

The need for solving transient boundary inverse heat conduction problems (IHCP), as a tool that allows one to obtain missing information on the object under consideration, can arise both when processing experimental results, and in the process of thermal measurements, and, in some cases, in the process of design. Therefore, as applied to VVER-based NPPs, the use of the IHCP solution results may be associated with processing of data in the process of commissioning measurements or equipment life monitoring in the course of the NPP operation. This paper proposes and describes a method for calculating boundary inverse heat conduction problems using a NARX-type recurrent neural network. Unknown weights and biases are calculated using the Levenberg – Marquardt gradient descent algorithm in the process of training based on a dedicated data set obtained by calculating a direct heat conduction problem using a series of randomly generated thermal loads. Several examples are provided to demonstrate the applicability of the methodology for solving linear and nonlinear heat conduction problems. Issues have been considered concerning the neural network parameters, such as time lags and the number of previous time steps under consideration. A two-dimensional problem has been discussed individually, which shows that introducing additional information into the input data makes it possible to reduce substantially the error in the obtained results. The results show minor deviations of the predicted temperature from the actual one under different inner surface boundary conditions. The developed methodology offers a major potential with respect to the VVER equipment temperature measurement issues, as well as to processing thermal experiment results..

Keywords: temperature, inverse heat conduction problem, recurrent neural network, VVER-based NPPs.

For citation: Deryabin I.A., Korolev V.V., Sorokin G.S. Using a Recurrent Neural Network for Solving Inverse Heat Conduction Problem with Application to Calculating the Temperature of Equipment of VVER-Based NPPs. *Izvestiya vuzov. Yadernaya Energetika*. 2024, no. 4, pp. 144–154. DOI: <https://doi.org/10.26583/npe.2024.4.12> (in Russian).

References

1. Alifanov O.M. *Inverse heat conduction problems*. Moscow, Mashinostroenie Publ., 1988. – 280 p. ISBN 5-217-00134-8 (in Russian).

2. Bogachev A.V., Dranchenko B.N., Semishkin V.P., Berkovich V.Ya. Development of the SAKOR-M system. *Voprosy atomnoy nauki i tekhniki. Seriya: Obespechenie bezopasnosti AES. Nauchno-tehnicheskiy sbornik: No. 15. Reactornye ustanovki VVER*. Podolsk, 2006 (in Russian).
3. Korolev V.V. Methodology for processing the results of monitoring temperatures and pressures in equipment elements of reactor plants. *Voprosy atomnoy nauki i tekhniki. Seriya: Obespechenie bezopasnosti AES. Nauchno-tehnicheskiy sbornik: No. 17. Reactornye ustanovki VVER*. Podolsk, 2007. (in Russian).
4. Deng S., Hwang Y. Applying neural networks to the solution of forward and inverse heat conduction problems. *International Journal of Heat and Mass Transfer*. 2006, vol. 49, iss. 25–26, pp. 4732–4750. DOI: <https://doi.org/10.1016/j.ijheatmasstransfer.2006.06.009>
5. Vasiliev A.N., Porubaev F.V., Tarkhov D.A. Neural network approaches to solving ill-posed heat transfer problems. *Nauchno-tehnicheskie vedomosti SPBGPU*. 2011, iss. 1, pp. 133–142 (in Russian).
6. Zhili He, Futao Ni, Weiguo Wang, Jian Zhang. A physics-informed deep learning method for solving direct and inverse heat conduction problems of materials. *Materials today communications*. 2021, vol. 28, 102719. DOI: <https://doi.org/10.1016/j.mtcomm.2021.102719>
7. Ruiz L.G.B., Cuéllar M.P., Calvo-Flores M.D., Jiménez M.D.C.P. An Application of Non-Linear Autoregressive Neural Networks to Predict Energy Consumption in Public Buildings. *Energies*. 2016, vol. 9, 684. DOI: <https://doi.org/10.3390/en9090684>
8. Jose Maria P.Menezes Jr, Guilherme A. Barreto. Long-term time series prediction with NARX network: An empirical evaluation. *Neurocomputing*. 2008, vol. 71, iss. 16–18, pp. 3335–3343. DOI: <https://doi.org/10.1016/j.neucom.2008.01.030>
9. Zubchenko A.S., Koloskov M.M., Kashirsky Yu.V. *Brand of steels and alloys*. Moscow, Mashinostroenie Publ., 2003, 784 p. (in Russian).

Authors

Ivan A. Deryabin, Leading design engineer,

E-mail: Deryabin_IA@grpress.podolsk.ru,

Vladimir V. Korolev, Leading design engineer, Cand. Sci (Phys.-Math.),

Georgy S. Sorokin, Head of group.