УДК 004.032.26 *DOI: 10.18287/2541-7533-2025-24-3-171-183*

ПРИМЕНЕНИЕ ПРОЦЕДУРЫ ОБУЧЕНИЯ НЕЙРОННОЙ СЕТИ ДЛЯ ВОССТАНОВЛЕНИЯ НЕИЗВЕСТНОГО ВОЗДЕЙСТВИЯ НА ТЕМПЕРАТУРНОЕ РАСПРЕДЕЛЕНИЕ СТЕНКИ БАРАБАНА КОТЛА

© 2025

И. А. Данилушкин кандидат технических наук, доцент, доцент кафедры автоматики и управления в технических системах;
Самарский государственный технический университет;
idanilushkin@mail.ru

А. Н. Дилигенская доктор технических наук, доцент, профессор кафедры автоматики и управления в технических системах;
Самарский государственный технический университет;
adiligenskaya@mail.ru

С. А. Колпащиков кандидат технических наук, доцент, заведующий кафедрой автоматики и управления в технических системах;
Самарский государственный технический университет;
skolpaschikov@mail.ru

Предложен новый способ восстановления неизвестного входного воздействия по измерениям выхода при известной динамической модели системы. В качестве формирующего устройства вектора опорных значений неизвестного входного воздействия выступает нейронная сеть прямого распространения. Динамическая модель системы включена в контур формирования вектора ошибки, которая минимизируется при обучении нейронной сети. Вектор ошибки формируется заново каждый раз после проведения очередной эпохи обучения нейронной сети. Для этого промежуточная оценка входного воздействия подаётся на вход при прогоне динамической модели системы. Предложена методика формирования вектора ошибки для реализации алгоритма обратного распространения при обучении нейронной сети по рассогласованию выхода модели и реальных данных. Определён набор гиперпараметров процедуры обучения. В качестве примера рассматривается задача восстановления неизвестного управляющего воздействия по данным процесса изменения температуры металла барабана парового котла. В примере используется модель температурного распределения по толщине стенки барабана, учитывающая влияние температуры среды на границах области определения пространственной координаты. Приведены результаты восстановления входного воздействия, показывающие работоспособность и достаточную точность предложенного способа.

Входное воздействие; идентификация; нейронная сеть прямого распространения; алгоритм обратного распространения ошибки; температурное распределение; барабан парового котла; объект с распределёнными параметрами

Цитирование: Данилушкин И.А., Дилигенская А.Н., Колпащиков С.А. Применение процедуры обучения нейронной сети для восстановления неизвестного воздействия на температурное распределение стенки барабана котла // Вестник Самарского университета. Аэрокосмическая техника, технологии и машиностроение. 2025. Т. 24, № 3. С. 171-183. DOI: 10.18287/2541-7533-2025-24-3-171-183

Введение

Актуальной задачей при создании систем автоматического управления является восстановление входного сигнала измерительного преобразователя по выходному сигналу при известной передаточной функции этого преобразователя. Эта задача актуальна также при коррекции систем управления, распознавания образов, встречается в теории связи, когда необходимо корректировать и фильтровать сигналы от внутриканальных искажений и шумов, а также в других прикладных задачах [1]. В ряде случаев динамика реальных систем определяется факторами, которые обычно неизвестны. Это справедливо для робототехники, биологии, химии, физики, экономики и т.д. [2]. В работах [3; 4] задача восстановления входного сигнала рассматривается как

один из этапов диагностики или обнаружения неисправностей. Проблема восстановления входного сигнала рассматривается в статьях, посвящённых изучению динамики в нелинейных биологических моделях и сетях биохимических реакций [5; 6]. В целом, можно выделить два основных подхода к решению задачи восстановления неизвестного входного сигнала: 1) с помощью формулировки обратных задач динамики и 2) путём решения задачи параметрической идентификации входного сигнала, определённого в виде взвешенной суммы набора базисных функций.

Обратные задачи динамики некорректны и требуют применения регуляризирующих процедур. Во многих работах [1 – 3]; [6 – 11] авторы предлагают оригинальные подходы к реализации метода регуляризации.

Подход, основанный на параметризации входного сигнала и последующей минимизации функционала отклонения выходных данных модели и реальных данных рассматривается в [5]; [12 – 17].

В [4] разработан алгоритм оценки входных данных, который рассчитывает входной вектор на каждом временном шаге, минимизируя оценку математического ожидания и дисперсии величины рассогласования выхода модели и реальных данных. В [5] представлен метод расчёта неизвестных параметров динамической модели и их оценки по выходным данным динамического объекта, демонстрируется целесообразность интегрированной стратегии анализа теоретической возможности определения состояний, параметров и входов системы и решения практической задачи оценки их значений.

В работах [7; 8] изучается задача динамической реконструкции неизвестного входа, действующего на систему обыкновенных дифференциальных уравнений, нелинейную по переменным состояния и линейную по управлению. Алгоритм основан на сочетании конструкций из теории некорректных задач с методом экстремального сдвига, применяющихся в позиционных дифференциальных играх. Работа [9] посвящена разработке методов реконструкции входных сигналов нестационарных динамических систем, основанных на численных алгоритмах и параметрической идентификации. Методы позволяют корректировать выходной сигнал динамической системы за счёт аппаратной или программной реализации обратного оператора к оператору, моделирующему измерительный преобразователь. В [10] предложен метод обработки данных, полученных в результате динамических измерений, основанный на конечно-разностном подходе. Для численной модели измерительной системы получен требуемый уровень точности восстановления входного сигнала за счёт обобщённого квазиоптимального подхода к выбору параметра регуляризации. В [11] автор рассматривает постановку, в которой неизвестное возмущение восстанавливается синхронно с процессом по неполной дискретной информации о части координат фазовой траектории. В [12] неизвестные входные воздействия параметризуются с использованием зависящих от времени базисных функций B-сплайна, что преобразует задачу в проблему параметрической идентификации.

Статьи [13 – 15] посвящены определению неизвестного граничного влияния объекта с распределёнными параметрами, описываемого уравнением в частных производных. В [13] рассматривается решение граничной обратной задачи теплопроводности на основе параметрической оптимизации искомой плотности теплового потока на априори выбранных компактах. Задача сводится к задаче параметрической оптимизации в равномерной оценочной метрике. В [14] авторы восстанавливают граничное управляющее воздействие двумерной задачи теплопроводности с использованием модального представления управляющего воздействия. В [15] восстановление неизвестного граничного влияния осуществляется с использованием временного ряда выходного сигнала в качестве входа радиальной базисной функции сети. Авторы предлагают обучать нейронную сеть на наборе выборок, сформированных из временных рядов параметризованных

управляющих воздействий и реакции на них объекта с распределёнными параметрами с известной передаточной функцией.

В работах [16; 17] рассматривается опыт применения нейронных сетей, учитывающих физические закономерности моделируемых процессов при решении задач идентификации. Для этого при обучении нейронных сетей в функцию потерь вводится дополнительное слагаемое, которое позволяет штрафовать нейронную сеть за отклик, не соответствующий заданной динамической модели. В [17] оценка эффективности подхода осуществляется по известному уравнению в частных производных для колебаний непрерывной балки. Авторы используют модальное представление решения при обучении нейронной сети. При решении задачи определения параметров распределённого входного воздействия заданного вида предложенный подход показал высокую точность.

Предлагаемая в настоящей работе методика может быть отнесена к задаче параметрической идентификации, её уникальностью является применение нейронной сети прямого распространения в качестве генератора искомого входного сигнала и метода обратного распространения ошибки для восстановления сигнала.

Постановка задачи

При эксплуатации паровых котлов одной из важных задач является контроль температуры металла массивных стальных элементов конструкций (барабанов, паропроводов, коллекторов). Интенсивный нагрев этих элементов может привести к чрезмерным термонапряжениям вследствие их существенной толщины. При растопке парового котла из холодного состояния барабан котла, представляющий собой горизонтально расположенный цилиндр диаметром 1,6 м и длиной образующей 18 м с толщиной стенки порядка 0,1 м, нагревается изнутри до температуры 340…350°С. Для предотвращения температурных напряжений по толщине оператор котла должен выдерживать определённую скорость повышения температуры. Барабан парового котла используется для разделения пара и воды, поэтому верхняя часть барабана нагревается паром, а нижняя часть – водой. Из-за разных значений коэффициентов теплопередачи нагрев верхней частей происходит более интенсивно, что при значительных размерах барабана может привести к деформации. Чтобы обеспечить равномерное расширение конструкции предусмотрена интенсификация прогрева нижней части барабана котла за счёт подачи в неё насыщенного пара давлением 14…16 МПа. Пар подаётся по двум коллекторам, расположенным в водяном объёме барабана котла. Регулируя подачу пара при растопке, оператор котла следит, чтобы разница температур металла верхней и нижней частей барабана не превышала 70°С.

Температура металла барабана котла является объектом управления со сложной динамикой, поэтому контроль температуры металла барабана обязательно включается как одна из задач, которую оператор должен освоить в процессе подготовки на компьютерном тренажёре. В рамках создания компьютерного тренажёра оператора разработана математическая модель температурного распределения по толщине стенки барабана котла [18]. Температурное распределение описывается одномерным уравнением теплопроводности с граничными условиями третьего рода [19] – распределение по толщине бесконечной пластины.

$$\frac{\partial Q(x,t)}{\partial t} = a\frac{\partial^2 Q(x,t)}{\partial x^2}, \quad 0 < x < L, \quad t > 0; \tag{1}$$

$$Q(x,0) = Q_0(x); \tag{2}$$

$$\frac{\partial Q(0,t)}{\partial x}=\frac{\alpha_1}{\lambda}\left(Q_1(t)-Q(0,t)\right),\qquad \frac{\partial Q(L,t)}{\partial x}=\frac{\alpha_2}{\lambda}\left(Q_2(t)-Q(L,t)\right), \tag{3}$$

где $Q(x,t)$ – температурное поле пластины; $Q_1(t)$, $Q_2(t)$ – температуры сред на границах пластины при $x=0$ и $x=L$; $a=\lambda/(c\gamma)$ – коэффициент температуропроводности: λ – коэффициент теплопроводности; c – удельная теплоёмкость; γ – плотность материала пластины; α_1, α_2 – коэффициенты теплопередачи на границах пластины; L – толщина.

В [18] решена задача идентификации параметров математической модели в предположении, что коэффициент теплопередачи между водой и металлом нижней части барабана котла изменяется в процессе растопки из-за роста давления в барабане. Такой подход обеспечил необходимую точность моделирования, но не позволил учесть воздействия оператора на процесс повышения температуры металла.

В настоящей работе решается задача оценки влияния подачи насыщенного пара на паровой разогрев котла. Необходимость восстановления неизвестного входного воздействия обусловлена тем, что система регистрации данных автоматизированной системы контроля парового котла не фиксирует никаких сведений ни о расходе пара на разогрев, ни о положении регулирующего клапана на трубопроводе подачи пара на разогрев. Влияние расхода пара вводится в модель через повышение температуры среды на внутренней границе стенки барабана.

Методика исследований

Задача (1) – (3) может быть представлена как краевая задача с граничными условиями второго рода, если принять, что

$$\frac{\partial Q(0,t)}{\partial x}=g_1(t),\qquad \frac{\partial Q(L,t)}{\partial x}=g_2(t), \tag{4}$$

$$g_1(t)=\frac{\alpha_1}{\lambda}\left(Q_1(t)-Q(0,t)\right), \tag{5}$$

$$g_2(t)=\frac{\alpha_2}{\lambda}\left(Q_2(t)-Q(L,t)\right)$$

Контроль температуры металла осуществляется с внешней стороны стенки, датчик размещается под теплоизолирующим материалом. Принято, что температура металла в точке контроля соответствует координате $x=0$. Неизвестное возмущение учитывается как повышение температуры среды $\Delta Q(t)$ на границе при $x=L$:

$$g_2(t)=\frac{\alpha_2}{\lambda}\left(Q_2(t)+\Delta Q(t)-Q(L,t)\right). \tag{6}$$

Для восстановления неизвестного входного сигнала разработана и реализована численная модель температуры металла в точке контроля, базирующаяся на решении краевой задачи (1), (2), (4). Решение задачи в виде изображения по Лапласу может быть найдено с помощью передаточной и стандартизирующей функций [20]:

$$W(x,\xi,p)=\frac{1}{L}\left[\frac{1}{p}+2\sum_{k=1}^{\infty}\frac{\cos(n\pi x/L)\cos(n\pi\xi/L)}{p+a(n\pi/L)^2}\right],$$

$$\omega(x,p)=Q_0(x)+a\delta(x)g_1(p)+a\delta(x-L)g_2(p).$$

При $Q_0(x)=0$, температурное распределение будет описываться как [22]:

$$\begin{aligned}Q(x,p)&=\int_0^L W(x,\xi,p)\omega(\xi,p)d\xi=\\&=g_1(p)\left(\frac{a}{Lp}+\frac{2a}{L}\sum_{k=1}^{\infty}\frac{\cos(n\pi x/L)\cos(0)}{p+a(n\pi/L)^2}\right)+\\&+g_2(p)\left(\frac{a}{Lp}+\frac{2a}{L}\sum_{k=1}^{\infty}\frac{\cos(n\pi x/L)\cos(n\pi)}{p+a(n\pi/L)^2}\right).\end{aligned}\qquad(7)$$

Выражение (7) с ограниченным количеством членов ряда использовалось для построения Simulink-модели температуры металла в точке контроля. С помощью библиотеки Control System Toolbox пакета инженерных расчётов MATLAB была рассчитана матричная передаточная функция [21] с двумя входами: температура среды на границах, и двумя выходами: температура металла на границах, – которая использовалась в качестве параметра блока LTI System при построении Simulink-модели.

Выражения (5), (6) для расчёта тепловых потоков реализованы с помощью охвата блока LTI System обратными связями (рис. 1).

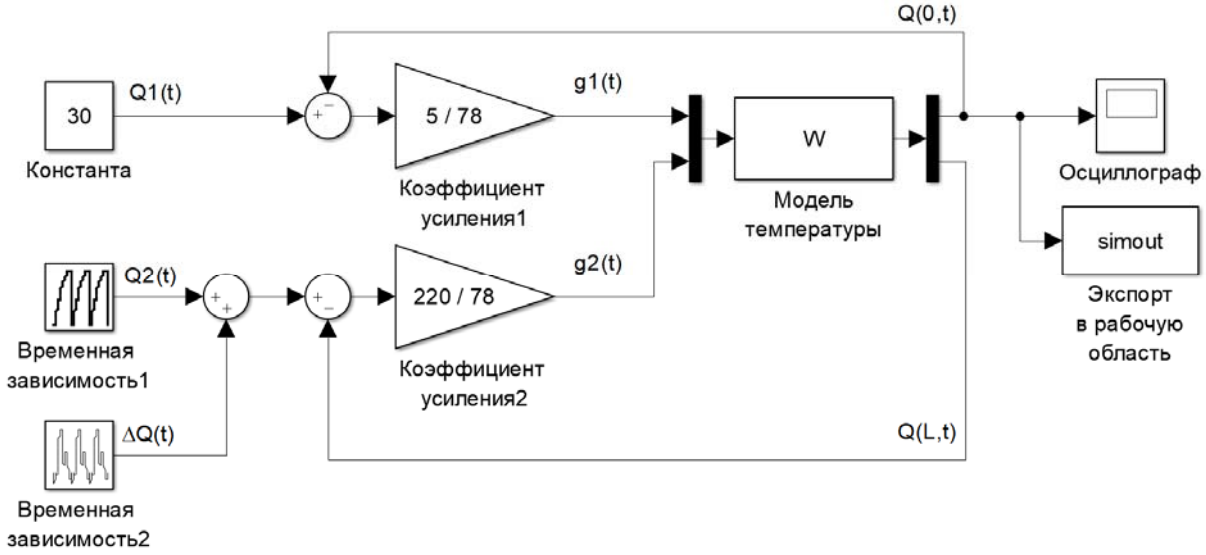


Рис. 1. Simulink-модель температуры металла в точке контроля

При реализации численной модели использовались параметры барабана котла марки БКЗ-420-140 НГМ: толщина стенки $L=0{,}112$ м; теплопроводность $\lambda=78$ Вт/(м·К); плотность материала стенки $\gamma=7834$ кг/м^3; теплоёмкость

$c = 469$ Дж/К. Коэффициенты теплопередачи на границах стенки $\alpha_1 = 5$ Вт/(м$^2\cdot$К) и $\alpha_2 = 220$ Вт/(м$^2\cdot$К) соответственно, были определены таким образом, чтобы установившийся режим модели совпадал с установившимся режимом реальных данных.

Решаемая задача может быть сформулирована следующим образом: необходимо восстановить неизвестное управляющее воздействие $\Delta Q(t)$, которое обеспечит минимальное отклонение температуры на выходе модели $Q(0,t)$ от реальных данных по температуре стенки барабана котла $Q^*_{cm}(t)$:

$$\max\left(\left|Q^*_{cm}(t) - Q(0,t)\right|\right) \to \min_{\Delta Q(t)}, \quad t \in [0, t_{end}].$$

Неизвестное управляющее воздействие $\Delta Q(t)$ предложено искать в виде вектора опорных значений

$$\mathbf{u} = \left[u_j\right]_{M\times 1}, \quad j = \overline{1, M},$$

который используется для задания сигнала $\Delta Q(t)$ в виде кусочно-постоянной функции

$$\Delta Q(t) = f_{\Delta Q}(\mathbf{u}, t) = u_{\min(\lfloor t/S \rfloor + 1, M)},$$

где M – количество временных интервалов; S – длительность временного интервала; $\lfloor \bullet \rfloor$ – операция округления к наименьшему ближайшему целому числу.

Сформулированная таким образом задача может быть решена путём варьирования элементов вектора опорных значений входного сигнала, что может быть реализовано известными численными методами решения задач оптимизации, например [22]. Однако опыт использования таких методов показывает, что при увеличении размерности вектора варьируемых параметров их эффективность снижается.

Решение поставленной задачи идентификации в данной работе выполнено с помощью алгоритма обратного распространения ошибки [23], который применяется при минимизации функции потерь в процессе обучении нейронных сетей. Для этого вычисление вектора опорных значений **u** осуществляется с помощью нейронной сети прямого распространения. Процедура обучения нейронной сети, формирующей вектор опорных значений, по сути, равносильна решению задачи идентификации.

Нейронная сеть прямого распространения (НСПР) формирует выход как отклик на входное воздействие. В данном случае входной сигнал выступает только как причина формирования выхода нейронной сети, на вход нейронной сети поступает постоянное значение – единица (рис. 2). В результате прямого прохода нейронной сети формируется вектор **u**, который затем используется для формирования неизвестного управляющего воздействия при прогоне динамической модели объекта с распределёнными параметрами (ОРП). С помощью прогона динамической модели рассчитывается функция рассогласования $e(t)$, которая используется далее для корректировки весов нейронной сети с помощью алгоритма обратного распространения ошибки.

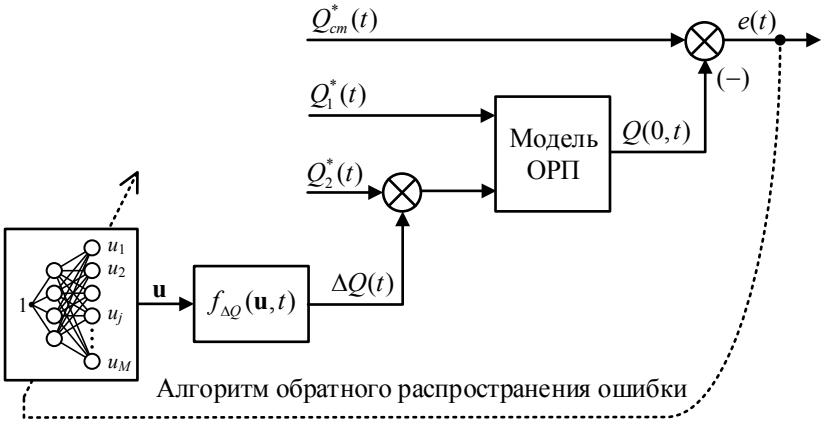


Рис. 2. Реализация обучения нейронной сети

Нейронная сеть должна научиться формировать вектор опорных значений, который соответствует восстанавливаемому управляющему воздействию. Алгоритм обратного распространения – алгоритм обучения с учителем, т.е. в процессе обучения нейронной сети должен быть предъявлен вектор *идеальных* опорных значений $\mathbf{u}^*$, который используется для формирования вектора минимизируемой ошибки $\boldsymbol{\varepsilon} = \mathbf{u}^* - \mathbf{u}$. В решаемой задаче вектор $\mathbf{u}^*$ неизвестен, поэтому вектор ошибки $\boldsymbol{\varepsilon}$ оценивается опосредованно, с помощью сигнала $e(t)$.

При расчёте значений вектора ошибки $\boldsymbol{\varepsilon}$ должны быть учтены следующие ограничения:

1) на сигнал рассогласования $e(t)$ в момент времени t никак не влияет управляющий сигнал более позднего времени;

2) влияние управляющего сигнала на сигнал рассогласования уменьшается с течением времени.

Таким образом, введя понятие «время нанесения управляющего воздействия» t_u, можно определить коэффициент влияния управляющего сигнала на сигнал рассогласования:

$$f_c(t,t_u) = \begin{cases} 0, & \text{при} \quad t_u > t; \\ \exp\left(-(t-t_u)/T\right), \end{cases}$$

где T – постоянная времени затухания влияния.

Для расчёта компонентов вектора ошибки по сигналу рассогласования формируется набор временных значений $t_k \in [0, t_{кон} - \Delta t)$, $k = \overline{1,K}$, где $t_{кон}$ – модельное время остановки прогона динамической модели ОРП; K – количество элементов в наборе; Δt – длительность временного интервала, на котором анализируется сигнал рассогласования. Для каждого t_k определяется максимальное значение сигнала рассогласования $e_k = e(\tau_k)$, такое, что:

$$\tau_k = \underset{\tau \in [t_k, t_k + \Delta t]}{\arg\max} \left(|e(\tau)| \right). \tag{8}$$

Моменты времени t_k, которые могут быть определены случайным образом, либо равномерно распределены по заданной области определения, используются для формирования набора векторов ошибки $\boldsymbol{\varepsilon}^{(k)} = \left[\varepsilon_j^{(k)} \right]_{M\times 1}$:

$$\varepsilon_j^{(k)} = e_k f_c\left(t_k, (j-1)S\right), \quad j = \overline{1, M} \ , \tag{9}$$

который, в свою очередь, используется для реализации алгоритма обратного распространения ошибки.

Таким образом, может быть реализован алгоритм обучения нейронной сети для восстановления неизвестного управляющего воздействия:

1) инициализировать нейронную сеть: определить структуру нейронной сети, инициализировать синапсические веса нейронной сети, задать количество эпох обучения, задать гиперпараметры обучения;

2) для каждой эпохи обучения выполнить:

2.1) рассчитать отклик нейронной сети $\mathbf{u}$;

2.2) сгенерировать набор временных значений $\{t_k\}$, $k = \overline{1, K}$;

2.3) выполнить прогон динамической модели ОРП;

2.4) для каждого k выполнить:

2.4.1) рассчитать значение сигнала рассогласования e_k согласно выражению (8);

2.4.2) рассчитать компоненты вектора ошибки $\boldsymbol{\varepsilon}^{(k)}$ согласно выражению (9);

2.4.3) выполнить корректировку синапсических весов с помощью алгоритма обратного распространения ошибки.

К гиперпараметрам алгоритма обучения отнесены: скорость обучения, количество элементов в наборе обучения K, длительность временного интервала Δt, способ формирования моментов времени t_k, постоянная времени затухания влияния управляющего воздействия T.

Для улучшения сходимости процедуры обучения значения гиперпараметров могут варьироваться в процессе обучения от эпохи к эпохе.

Главное отличие предложенного алгоритма от известных алгоритмов обучения нейронных сетей [23] заключается в опосредованной оценке вектора ошибки и формировании обучающей выборки после каждой эпохи обучения за счёт прогона динамической модели ОРП.

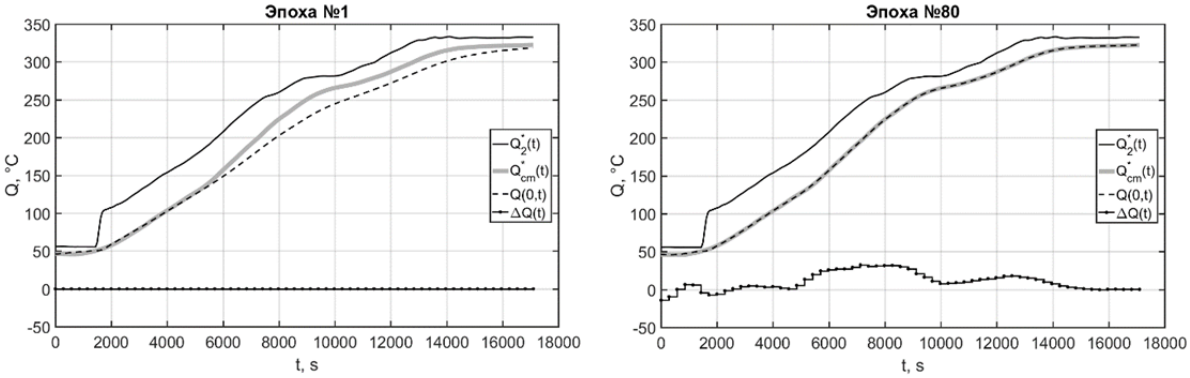
Результаты и их обсуждение

Предложенный алгоритм был реализован в пакете MATLAB [24]. Расчёт отклика нейронной сети и алгоритм обратного распространения ошибки выполнены в виде текста программы на алгоритмическом языке MATLAB. После каждой эпохи обучения осуществляется прогон Simulink-модели (рис. 2) с новыми значениями вектора $\mathbf{u}$.

На рис. 3, *а* представлены графики изменения температуры насыщенного пара в барабане котла и температуры металла в нижней части барабана, фактическая и рассчитанная с помощью модели на рис. 1, при отсутствии управляющего воздействия $\Delta Q(t)$. На рис. 3, *б* представлены графики, полученные в результате выполнения 80 эпох обучения нейронной сети прямого распространения со структурой 1-8-16-60. В качестве функций активации первого и второго скрытых слоёв использовался гиперболический тангенс, функция активации выходного слоя – линейная. Обучение проводилось со следующими значениями гиперпараметров: скорость обучения 0,002; длительность

временного интервала Δt на каждой эпохе формировалась как случайное целое число с равномерным распределением в диапазоне от 2 до 10 минут; постоянная времени затухания влияния управляющего воздействия T формировалось как случайное целое число с равномерным распределением в диапазоне от 1 до 12 минут.

Максимальное абсолютное рассогласование температуры металла, $\left|Q_{cm}^{*}(t)-Q(0,t)\right|$ на всём диапазоне имеющихся реальных данных составляет 1,5°C, что соизмеримо с точностью измерительной системы.



а *б*

Рис. 3. Изменение температур в процессе растопки в начале (а) и в конце (б) обучения

Полученное управляющее воздействие может быть пересчитано в положение регулирующего клапана, отвечающего за подачу насыщенного пара. Для этого должны быть учтены перепад давления между источником пара и нагреваемым барабаном, а также объём и температура воды, находящиеся в барабане.

Отрицательные значения управляющего воздействия в начале графика не соответствуют реальности: за счёт них компенсируются неизвестные динамические процессы, протекающие на этапе растопки до включения горелок в топке котла. Ограничение области определения восстанавливаемого входного воздействия может быть введено в виде штрафа в процедуру формирования вектора ошибки на этапе обучения нейронной сети.

Заключение

Представленный в работе подход показал свою эффективность и может быть использован во многих практически полезных случаях при известной динамической модели исследуемой системы и ограниченном неизвестном входном воздействии. В качестве неизвестного входного воздействия может выступать и пространственно-распределённый сигнал, заданный в виде пространственной конфигурации опорных точек, либо в виде параметризованной функции пространства и времени. Дальнейшее исследование предложенного подхода может заключаться в разработке рекомендаций по выбору гиперпараметров алгоритма, в том числе в зависимости от динамических характеристик системы, а также в модернизации предложенного алгоритма для его реализации с помощью известных библиотек создания и обучения нейронных сетей.

Исследование выполнено за счёт гранта Российского научного фонда № 23-29-00521, https://rscf.ru/project/23-29-00521/, ФГБОУ ВО «Самарский государственный технический университет»

Библиографический список

1. Бойков И.В., Кривулин Н.П. Восстановление входных сигналов дискретных динамических систем // Измерительная техника. 2017. № 11. С. 3-7.

2. Martinelli A. Nonlinear unknown input observability and unknown input reconstruction: The general analytical solution // Information Fusion. 2022. V. 85. P. 23-51. DOI: 10.1016/j.inffus.2022.03.004

3. Barbot J.-P., Boutat D., Floquet T. An observation algorithm for nonlinear systems with unknown inputs // Automatica. 2009. V. 45, Iss. 8. P. 1970-1974. DOI: 10.1016/j.automatica.2009.04.009

4. Curi S., Levy K.Y., Krause A. Adaptive input estimation in linear dynamical systems with applications to learning-from-observations // Proceedings of the 58th IEEE Conference on Decision and Control, CDC 2019 (December, 11-13, 2019, Nice, France). P. 4115-4120. DOI: 10.1109/CDC40024.2019.9029379

5. Villaverde A.F., Tsiantis N., Banga J.R. Full observability and estimation of unknown inputs, states and parameters of nonlinear biological models // Journal of the Royal Society Interface. 2019. V. 16, Iss. 156. DOI: 10.1098/rsif.2019.0043

6. Schelker M., Raue A., Timmer J., Kreutz C. Comprehensive estimation of input signals and dynamics in biochemical reaction networks // Bioinformatics. 2012. V. 28, Iss. 18. P. i529-i534. DOI: 10.1093/bioinformatics/bts393

7. Близорукова М.С. О восстановлении неизвестного входа системы дифференциальных уравнений // Труды института математики и механики УрО РАН. 2021. Т. 27, № 2. С. 59-66. DOI: 10.21538/0134-4889-2021-27-2-59-66

8. Максимов В.И. Восстановление неограниченного входного воздействия системы дифференциальных уравнений // Труды Математического института имени В.А. Стеклова. 2021. Т. 315. С. 160-171. DOI: 10.4213/tm4226

9. Кривулин Н.П. Восстановление входных сигналов нестационарных динамических систем // Известия высших учебных заведений. Поволжский регион. Физико-математические науки. 2018. № 3 (47). С. 64-78. DOI: 10.21685/2072-3040-2018-3-6

10. Япаров Д.Д., Шестаков А.Л. Метод восстановления входного сигнала в динамических системах на основе дискретной модели с исключением корректирующих обратных связей // Вестник Южно-Уральского государственного университета. Серия: Компьютерные технологии, управление, радиоэлектроника. 2022. Т. 22, № 4. С. 56-66. DOI: 10.14529/ctcr220406

11. Розенберг В.Л. К задаче динамической реконструкции возмущения в нелинейной системе дифференциальных уравнений // Труды института математики и механики УрО РАН. 2021. Т. 27, № 2. С. 197-207. DOI: 10.21538/0134-4889-2021-27-2-197-207

12. Vyasarayani C.P., Manikantan R., Chakraborty S. Unknown input reconstruction in non-linear dynamical systems using homotopy optimization // Vibroengineering Procedia. 2019. V. 29. P. 279-284. DOI: 10.21595/vp.2019.21141

13. Дилигенская А.Н., Золотарёва В.В. Параметрическая идентификация граничного воздействия на компактных множествах заданной формы // Математические методы в технологиях и технике. 2022. № 12, ч. 1. С. 7-10. DOI: 10.52348/2712-8873_MMTT_2022_12_07

14. Рапопорт Э.Я., Дилигенская А.Н. Модальная идентификация граничного воздействия в двумерной обратной задаче теплопроводности // Вестник Самарского государственного технического университета. Серия: Физико-математические науки. 2018. Т. 22, № 2. С. 380-394. DOI: 10.14498/vsgtu1627

15. Diligenskaya A., Samokish A. Parametric identification of technological thermophysics processes based on neural network approach // Journal of Vibroengineering. 2021. V. 23, Iss. 6. P. 1407-1417. DOI: 10.21595/jve.2021.22075

16. Haywood-Alexander M., Arcieri G., Kamariotis A., Chatzi E. Response estimation and system identification of dynamical systems via physics-informed neural networks // Advanced Modeling and Simulation in Engineering Sciences. 2025. V. 12, Iss. 8. DOI: 10.1186/s40323-025-00291-9

17. Moradi S., Duran B., Eftekhar Azam S., Mofid M. Novel physics-informed artificial neural network architectures for system and input identification of structural dynamics PDEs // Buildings. 2023. V. 13, Iss. 3. DOI: 10.3390/buildings13030650

18. Данилушкин И.А., Колпащиков С.А., Левин И.С. Численно-аналитическая модель температуры металла барабана парового котла // Вестник Самарского государственного технического университета. Серия: Технические науки. 2023. Т. 31, № 1 (77). С. 21-33. DOI: 10.14498/tech.2023.1.2

19. Лыков А.В. Теория теплопроводности. М.: Высшая школа, 1967. 599 с.

20. Бутковский А.Г. Структурная теория распределённых систем. М.: Наука, 1977. 320 с.

21. Данилушкин И.А., Колпащиков С.А. Моделирование температуры металла стенки барабана парового котла в Simulink // Материалы XII Всероссийской научной конференции с международным участием «Математическое моделирование и краевые задачи» (17-19 сентября 2024 г., Самара, Россия). Т. 1. Самара: СамГТУ, 2024. С. 97-99.

22. Lagarias J.C., Reeds J.A., Wright M.H., Wright P.E. Convergence properties of the Nelder-Mead simplex method in low dimensions // SIAM Journal of Optimization. 1998. V. 9, Iss. 1. P. 112-147. DOI: 10.1137/S1052623496303470

23. Haykin S. Neural networks and learning machines. Pearson Education, 2009. 938 p.

24. Данилушкин И.А. Пример реализации в MATLAB+Simulink алгоритма восстановления неизвестного входа по известному выходу и модели динамической системы. https://github.com/idanilushkin/BP4unknownInputReconstruction

APPLICATION OF THE NEURAL NETWORK TRAINING PROCEDURE TO RECONSTRUCT AN UNKNOWN INFLUENCE ON THE TEMPERATURE DISTRIBUTION OF THE BOILER DRUM WALL

© 2025

I. A. Danilushkin — Candidate of Science (Engineering), Associate Professor, Associate Professor of the Department of Automation and Control in Technical Systems; Samara State Technical University, Samara, Russian Federation; idanilushkin@mail.ru

A. N. Diligenskaya — Doctor of Science (Engineering), Associate Professor, Professor of the Department of Automation and Control in Technical Systems; Samara State Technical University, Samara, Russian Federation; adiligenskaya@mail.ru

S. A. Kolpashchikov — Candidate of Science (Engineering), Associate Professor, Head of the Department of Automation and Control in Technical Systems; Samara State Technical University, Samara, Russian Federation; skolpaschikov@mail.ru

The paper proposes a novel method for reconstructing an unknown input influence based on output measurements with a known dynamic model of the system. A feedforward neural network acts as a device for forming the vector of reference values of the unknown input influence. The dynamic model of the system is included in the loop of formation of the error vector, which is minimized in the neural network training. The error vector is formed anew each time after the next epoch of neural network training. For this purpose, an intermediate estimate of the input influence is fed into the input during the simulation of the system's dynamic model. The paper proposes a method of error vector formation for the realization of the back propagation algorithm when training a neural network by the mismatch between the model output and real data. A set of hyperparameters of the training procedure is defined. As an example, we consider the problem of reconstructing an unknown control influence based on data from the temperature change process in the metal of a steam boiler drum. The example uses a model of temperature distribution across the thickness of the drum wall, which takes into account the influence of the ambient temperature at the boundaries of the spatial coordinate domain. The results of input influence reconstruction are presented, demonstrating the performance and sufficient accuracy of the proposed method.

Input influence; identification; feed forward neural network; back propagation algorithm; temperature distribution; steam boiler drum; object with distributed parameters

Citation: Danilushkin I.A., Diligenskaya A.N., Kolpashchikov S.A. Application of the neural network training procedure to reconstruct an unknown influence on the temperature distribution of the boiler drum wall. *Vestnik of Samara University. Aerospace and Mechanical Engineering*. 2025. V. 24, no. 3. P. 171-183. DOI: 10.18287/2541-7533-2025-24-3-171-183

References

1. Boikov I.V., Krivulin N.P. Recovering the input signals of discrete dynamical systems. *Measurement Techniques*. 2018. V. 60, Iss. 11. P. 1073-1080. DOI: 10.1007/s11018-018-1320-x

2. Martinelli A. Nonlinear unknown input observability and unknown input reconstruction: The general analytical solution. *Information Fusion*. 2022. V. 85. P. 23-51. DOI: 10.1016/j.inffus.2022.03.004

3. Barbot J.-P., Boutat D., Floquet T. An observation algorithm for nonlinear systems with unknown inputs. *Automatica*. 2009. V. 45, Iss. 8. P. 1970-1974. DOI: 10.1016/j.automatica.2009.04.009

4. Curi S., Levy K.Y., Krause A. Adaptive input estimation in linear dynamical systems with applications to learning-from-observations. *Proceedings of the 58th IEEE Conference on Decision and Control, CDC 2019 (December, 11-13, 2019, Nice, France)*. P. 4115-4120. DOI: 10.1109/CDC40024.2019.9029379

5. Villaverde A.F., Tsiantis N., Banga J.R. Full observability and estimation of unknown inputs, states and parameters of nonlinear biological models. *Journal of the Royal Society Interface*. 2019. V. 16, Iss. 156. DOI: 10.1098/rsif.2019.0043

6. Schelker M., Raue A., Timmer J., Kreutz C. Comprehensive estimation of input signals and dynamics in biochemical reaction networks. *Bioinformatics*. 2012. V. 28, Iss. 18. P. i529-i534. DOI: 10.1093/bioinformatics/bts393

7. Blizorukova M.S. On the reconstruction of an unknown input of a system of differentialequations. *Trudy Instituta Matematiki i Mekhaniki UrO RAN*. 2021. V. 27, no. 2, P. 59-66. (In Russ.). DOI: 10.21538/0134-4889-2021-27-2-59-66

8. Maksimov V.I. Reconstruction of an unbounded input of a system of differential equations. *Proceedings of the Steklov Institute of Mathematics*. 2021. V. 315, Iss. 1. P. 149-160. DOI: 10.1134/S0081543821050114

9. Krivulin N.P. Recovering input signals of non stationary dynamical systems. *University Proceedings. Volga Region. Physical and Mathematical Sciences*. 2018. No. 3 (47). P. 64-78. (In Russ.). DOI: 10.21685/2072-3040-2018-3-6

10. Yaparov D.D., Shestakov A.L. Method for recovery of the input signal in dynamic systems based on a discrete model with the exclusion of correcting feedbacks. *Bulletin of the*

South Ural State University. Series Computer Technologies, Automatic Control, Radio Electronics. 2022. V. 22, no. 4. P. 56-66. (In Russ.). DOI: 10.14529/ctcr220406

11. Rozenberg V.L. On a problem of dynamic disturbance reconstruction in a nonlinear system of differential equations. *Trudy Instituta Matematiki i Mekhaniki UrO RAN*. 2021. V. 27, no. 2. P. 197-207. (In Russ.). DOI: 10.21538/0134-4889-2021-27-2-197-207

12. Vyasarayani C.P., Manikantan R., Chakraborty S. Unknown input reconstruction in non-linear dynamical systems using homotopy optimization. *Vibroengineering Procedia*. 2019. V. 29. P. 279-284. DOI: 10.21595/vp.2019.21141

13. Diligenskaya A.N., Zolotareva V.V Parametric identification of the boundary action on the specified compact sets. *Matematicheskie Metody v Tekhnologiyakh i Tekhnike*. 2022. No. 12, part 1. P. 7-10. (In Russ.). DOI: 10.52348/2712-8873_MMTT_2022_12_07

14. Rapoport E.Ya., Diligenskaya A.N. Modal identification of a boundary input in the two-dimensional inverse heat conduction problem. *Vestnik Samarskogo Gosudarstvennogo Tekhnicheskogo Universiteta, Seriya Fiziko-Matematicheskie Nauki*. 2018. V. 22, no 2. P. 380-394. (In Russ.). DOI: 10.14498/vsgtu1627

15. Diligenskaya A., Samokish A. Parametric identification of technological thermophysics processes based on neural network approach. *Journal of Vibroengineering*. 2021. V. 23, Iss. 6. P. 1407-1417. DOI: 10.21595/jve.2021.22075

16. Haywood-Alexander M., Arcieri G., Kamariotis A., Chatzi E. Response estimation and system identification of dynamical systems via physics-informed neural networks. *Advanced Modeling and Simulation in Engineering Sciences*. 2025. V. 12, Iss. 8. DOI: 10.1186/s40323-025-00291-9

17. Moradi S., Duran B., Eftekhar Azam S., Mofid M. Novel physics-informed artificial neural network architectures for system and input identification of structural dynamics PDEs. *Buildings*. 2023. V. 13, Iss. 3. DOI: 10.3390/buildings13030650

18. Danilushkin I.A., Kolpashchikov S.A., Levin I.S. Numerical analytical model of metal temperature of steam boiler drum. *Vestnik of Samara State Technical University. Technical Sciences Series*. 2023. V. 31, no. 1 (77). P. 21-33. (In Russ.). DOI: 10.14498/tech.2023.1.2

19. Lykov A.V. *Teoriya teploprovodnosti* [Theory of heat conduction]. Moscow: Vysshaya Shkola Publ., 1967. 599 p.

20. Butkovskiy A.G. *Strukturnaya teoriya raspredelennykh sistem* [Structural theory of distributed systems]. Moscow: Nauka Publ., 1977. 320 p.

21. Danilushkin I.A., Kolpashchikov S.A. Modeling the metal temperature of a steam boiler drum wall in Simulink. *Proceedings of the XII All-Russian Scientific Conference with International Participation «Mathematical Modeling and Boundary Value Problems» (September, 17-19, 2024, Samara, Russian Federation)*. V. 1. Samara: Samara State Technical University Publ., 2024. P. 97-99. (In Russ.)

22. Lagarias J.C., Reeds J.A., Wright M.H., Wright P.E. Convergence properties of the Nelder-Mead simplex method in low dimensions. *SIAM Journal of Optimization*. 1998. V. 9, Iss. 1. P. 112-147. DOI: 10.1137/S1052623496303470

23. Haykin S. Neural networks and learning machines. Pearson Education, 2009. 938 p.

24. Danilushkin I.A. *Primer realizatsii v MATLAB+Simulink algoritma vosstanovleniya neizvestnogo vkhoda po izvestnomu vykhodu i modeli dinamicheskoy sistemy* [MATLAB+Simulink example implementing the backpropagation algorithm to reconstruct the unknown input of a system with distributed parameters, based on a known model and output data]. Available at:
https://github.com/idanilushkin/BP4unknownInputReconstruction