

Нейросетевое моделирование теплогидравлической эффективности перспективных поверхностных интенсификаторов теплообмена

К.Х. ГИЛЬФАНОВ,

д-р техн. наук

(КГЭУ, Казань),

Р.А. ШАКИРОВ,

аспирант

(ООО «Газпром Трансгаз

Чайковский», Чайковский)

kamil.gilfanov@yandex.ru

Представлена методика нейросетевого моделирования теплогидравлической эффективности при поверхностной интенсификации теплообменного оборудования. Получены результаты нейросетевого моделирования для различных поверхностных интенсификаторов. Для обучения искусственной нейронной сети использованы данные экспериментальных исследований.

Теплоотдача, гидравлическое сопротивление, искусственная нейронная сеть, поверхностные интенсификаторы теплообмена

Современный этап развития авиационной и энергетической промышленности характеризуется ужесточением требований к энерго- и ресурсосбережению технологических процессов. Энергоэффективность всего производства напрямую зависит от эффективности теплообменного оборудования, так как вся вырабатываемая и используемая энергия многократно проходит преобразование в различных теплообменных устройствах. Повышение эффективности теплообменного оборудования связано с использованием поверхностных интенсификаторов теплообмена, поскольку данный метод позволяет снизить термическое сопротивление пристенных слоев при конвективном теплообмене вблизи теплообменной поверхности, способствуя повышению коэффициента теплоотдачи.

В технической литературе имеется огромная база данных по пассивной интенсификации теплообмена. Физические принципы данного способа интенсификации известны уже давно. Однако количественные зависимости для расчета коэффициентов теплоотдачи и гидравлического сопротивления в широком диапазоне изменения геометрических параметров вихрегенераторов и режимных характеристик определены пока не в полной мере. Обобщить характеристики поверхностных интенсификаторов теплообмена общепринятыми уравнениями сохранения не удастся ввиду сложности тепловых и гидромеханических процессов [1]. Если и удастся обобщить результаты исследований в виде эмпирических формул зависимости чисел Нуссельта от чисел Рейнольдса и Прандтля с привлечением определяющих размеров, то, как правило, для узкого класса поверхностных интенсификаторов в диапазоне параметров проведенных экспериментов [2].

Для обобщения результатов исследований в данной области требуются методы, позволяющие работать с параметрами за пределами диапазонов, в рамках которых были проведены опыты. Одним из таких методов, предлагающих решение данной проблемы, являются искусственные нейронные сети (ИНС). ИНС – аппаратно-программная реализация математической модели, построенной по принципу организации и функционирования биологических нейронных сетей. Обобщение опытных данных различных исследований в данной области позволит сформировать логические взаимосвязи между геометрическими и режимными параметрами поверхностных интенсификаторов теплообмена, что дает возможность работать с данными, не вошедшими в диапазон параметров, полученных опытным путем.

Задача ИНС заключается в прогнозировании теплогидравлической эффективности на основе режимных и геометрических параметров интенсифицированной теплообменной поверхности. Теплогидравлическая эффективность выражена отношением

$$\frac{Nu/Nu_0}{\xi/\xi_0},$$

где Nu , Nu_0 – число Нуссельта для интенсифицированной и гладкой поверхностей; ξ , ξ_0 – гидравлическое сопротивление для интенсифицированной и гладкой поверхностей.

Разработка нейросетевой модели состоит из следующих основных этапов: формирование обучающей и тестовой выборки, нормализация входных и выходных параметров, разработка архитектуры ИНС, обучение, оптимизация и тестирование сети.

Обучающие и тестовые выборки сформированы на основе экспериментальных параметров, полученных в рамках исследований поверхностной интенсификации теплоотдачи и гидравлического сопротивления [1–25]. Обучающая выборка представляет собой матрицу из 11 столбцов и более 1000 строк. Одна строка обучающей выборки представляет собой один обучающий набор экспериментальных параметров. Тестовая выборка состоит из экспериментальных данных, не вошедших в обучающую выборку.

В таблице представлена часть обучающей выборки экспериментальных параметров для поперечных кольцевых выступов.

$L, \text{ м}$	$t, \text{ м}$	$h, \text{ м}$	$d, \text{ м}$	$D, \text{ м}$	t/h	t/d	d/D	Pr	Re	$(\text{Nu} / \text{Nu}_0) / (\xi / \xi_0)$
1	0,009	0,0013	0,0074	0,01	6,9230	1,2162	0,740	3,56	1200	0,99
1	0,0138	0,0019	0,0121	0,016	7,2251	1,1333	0,761	3,56	1200	0,72
1	0,013	0,0013	0,0133	0,016	9,7744	0,9742	0,834	3,56	1200	0,55
1	0,006	0,0005	0,009	0,01	12	0,6666	0,900	3,56	1200	0,48
1	0,01	0,0001	0,0098	0,01	100	1,0204	0,980	3,56	1200	0,52
0,76	0,009	0,0013	0,0074	0,01	6,9230	1,2162	0,740	3,56	1400	0,31

Примечание: L – длина трубы; t – расстояние между интенсификаторами; h – глубина или высота интенсификатора; d – диаметр трубы по вершинам выступов; D – внутренний диаметр трубы.

Для повышения точности работы ИНС необходимо произвести нормализацию входных и выходных параметров. С приближением значений параметров к диапазону функции активации ускоряется корректировка весов. На выходе ИНС функцией активации является сигмоида, поэтому необходимо сделать нормировку для выходных параметров обучающей выборки, опустив минимальные значения до нуля:

$$y_n = Y - Y_{\min},$$

где Y – исходные данные выходных параметров обучающей выборки; Y_{\min} – минимальное значение исходных данных выходных параметров обучающей выборки.

Максимальные значения выборки необходимо привести к единице:

$$X_n = \frac{Y}{y_{n\max}},$$

где $y_{n\max}$ – максимальное значение смещенной выборки выходных параметров.

Входные параметры ИНС также необходимо нормализовать. Для этого выполняется следующее:

$$x_n = \frac{X - S}{\sigma},$$

где X – исходная матрица обучающих данных; S – среднее арифметическое матрицы обучающих данных; σ – стандартное отклонение.

Обучение ИНС основано на методе многовариантных исчислений. Погрешность прогнозирования одного цикла обучения представлена как функция веса и смещения M :

$$M(w_1, w_2, w_n, b_1, b_2, b_n),$$

где w_n – вес сигнала, поступающий на вход нейрона; b_n – смещение каждого нейрона ИНС.

Точность работы ИНС оценивается среднеквадратической ошибкой (MSE):

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - y_p)^2,$$

где n – число рассматриваемых объектов; y_i – истинное значение; y_p – предполагаемое значение ИНС.

Основной задачей при обучении ИНС является определение величины потери M в случае изменения веса сигнала w_1 . Для этого производятся следующие операции:

$$\frac{\partial M}{\partial y_p} = \frac{\partial M}{\partial y_p} \frac{\partial y_p}{\partial w_1};$$

$$\frac{\partial M}{\partial y_p} = \frac{\partial (y_l - y_p)^2}{\partial y_p} = -2(y_l - y_p);$$

$$\frac{\partial y_p}{\partial w_1} = \frac{\partial y_p}{\partial h_1} \frac{\partial h_1}{\partial w_1};$$

$$\frac{\partial y_p}{\partial h_1} = w_{101} f' (w_{101} h_1 + w_{102} h_2 + w_{103} h_3 \dots + w_n h_n + b_{11}),$$

где f – функция активации сигмоида.

Аналогичные действия проводятся для $\frac{\partial h_1}{\partial w_1}$.

Таким образом, $\frac{\partial M}{\partial w_1}$ разбита на несколько частей:

$$\frac{\partial M}{\partial w_1} = \frac{\partial M}{\partial y_p} \frac{\partial y_p}{\partial h_1} \frac{\partial h_1}{\partial w_1}.$$

Аналогичные операции проводятся для каждого нейрона ИНС.

Таким образом, принцип потери, применяемый в процессе обучения, состоит в том, что меньшие потери соответствуют наилучшим результатам ИНС, а тренировка нейронной сети заключается в стремлении минимизировать потери. Векторы обучающего множества предъявляются последовательно, вычисляются ошибки, и веса подстраиваются для каждого вектора до тех пор, пока ошибка по всему обучающему массиву не достигнет приемлемо низкого уровня. Для задания начальных значений весовых коэффициентов используется статистическая настройка, предназначенная для того, чтобы на основе дополнительной информации о данных несколько улучшить алгоритм начальной инициализации.

Для оптимизации полученных результатов использован алгоритм стохастического градиентного спуска, который позволяет изменять вес и смещения для минимизации потерь. Это отражается в следующем уравнении:

$$w_1 \leftarrow w_1 - \eta \frac{\partial M}{\partial w_1},$$

где η – константа оценки обучения.

Принципы оптимальности сформированы следующим образом: если $\frac{\partial M}{\partial w_1}$ положительная, w_1 уменьшится, что приведет к уменьшению потери M . Если $\frac{\partial M}{\partial w_1}$ отрицательная, w_1 увеличится, что приведет к уменьшению потери M . Таким образом, для каждого входного нейрона изменение входных переменных в диапазоне истинных уровней должно сопровождаться одинаковым изменением выходного сигнала нейрона, и уровень смещения для каждого нейрона должен быть установлен так, чтобы обеспечить в среднем по обучающей выборке максимальное значение производной для функции активации. С применением этого принципа в случае каждого веса и смещения в сети потеря будет постепенно снижаться, а показатели сети улучшаться.

Заключительным этапом в процессе разработки нейросетевой модели является тестирование ИНС. Тестирование позволяет оценить качество сформированных взаимосвязей между геометрическими и режимными параметрами поверхностных интенсификаторов теплообмена, т.е. качество работы ИНС с реальными данными. ИНС реализована на базе высокоуровневого языка программирования Python, в алгоритм которого заложены описанные принципы и методы. Полученные результаты тестирования работы ИНС представлены для каждого рассмотренного типа поверхностных интенсификаторов теплообмена.

Поперечные кольцевые выступы характеризуются высокой тепловой эффективностью и технологичностью. Для обучения и тестирования ИНС использованы экспериментальные параметры исследований [2–5]. Полученные результаты нейросетевого моделирования представлены на рис. 1. Здесь и на рис. 2–10: a – ошибка обучения ИНС; b – разброс спрогнозированных значений относительно верных; позиции 1, 2 – средняя абсолютная ошибка на обучающем и проверочном наборе.




Рис. 1

Тестирование ИНС показывает, что результаты прогнозирования теплогидравлической эффективности с достаточно высокой точностью расположены относительно верных результатов, за исключением трех выбросов (рис. 1, б). Это связано с тем, что параметры данных значений обучающей выборки имеют погрешность, связанную с погрешностью измерения экспериментальных данных. Погрешность работы ИНС составила 1,65 %.

Полусферические выступы, по сравнению с кольцевыми, существенно уменьшают сужение проходного сечения трубы. ИНС для работы с полусферическими выступами обучена на основе экспериментальных данных исследований [6–9].

Результаты тестирования сети представлены на рис. 2.




Рис. 2

Как видим (рис. 2, б), в тестовом наборе есть значение, которое значительно отклоняется от действительных значений тестовой выборки. Скорее всего, в тестовом наборе данных будут значительные аномалии, которые позволят сделать вычистку данных. Погрешность работы ИНС составляет 1,03 %.

Безотрывное профилирование сферических выемок позволяет реализовать конфузorno-диффузорное течение. Обучающая выборка для данного типа интенсификаторов сформирована на базе экспериментальных исследований [10–13].

Результаты работы ИНС представлены на рис. 3.




Рис. 3

Как видим (рис. 3, а), ошибка на проверочном наборе начинает возрастать. Таким образом, требуется расширение обучающих данных, что также подтверждается на графике разброса предсказанных значений относительно верных (рис. 3, б). Погрешность ИНС составляет 1,34 %.

Капельные (миндалевидные) углубления позволяют реализовать режим течения, при котором возрастает теплоотдача по сравнению с гидросопротивлением. Обучающие данные сформированы на основе опытных данных исследований [14].

Результаты тестирования ИНС представлены на рис. 4.




Рис. 4

Результаты нейросетевого моделирования для данного типа поверхностных интенсификаторов показывают высокую точность обучения и предсказания. Погрешность работы ИНС составляет 0,53 %.

В научно-технической литературе существует ограниченное количество публикаций, в которых исследуются теплогидравлические характеристики трактов с V-образными углублениями. Обучающие данные сформированы на основе опытных данных исследований [15].

Результаты тестирования ИНС представлены на рис. 5.




Рис. 5

Результаты нейросетевого моделирования для V-образных углублений также показывают высокую точность работы ИНС. Погрешность работы ИНС составляет 0,77 %.

Для эллиптических выемок поверхностных интенсификаторов характерно увеличение теплового потока для участков втекания теплоносителя в траншею и истечения из нее, а в самой траншее интенсивность теплоотдачи оказывается более низкой, чем на гладкой стенке. Для обучения ИНС использован экспериментальный материал [16, 17].

Результаты тестирования ИНС представлены на рис. 6.

Разброс спрогнозированных значений относительно верных по данному типу поверхностных интенсификаторов теплообмена показывает высокую точность, но ошибки обучения на обучающем и тестовом наборе не сходятся при эпохе обучения, равной двумстам. В связи с этим обучающую выборку необходимо дополнить опытными данными. Погрешность работы ИНС – 0,65 %.

Применение подковообразных выемок эффективно при пульсирующем потоке газовой рабочей среды. При работе с жидкими средами увеличение теплоотдачи сопровождается

увеличением гидравлического сопротивления. Для обучения ИНС использован экспериментальный материал [17].




Рис. 6

Результаты тестирования ИНС представлены на рис. 7.




Рис. 7

Результаты нейросетевого моделирования аналогичны полученным в случае эллиптических выемок. Несмотря на высокую точность предсказания, из-за ошибки обучения возникает необходимость дополнения обучающей выборки опытными данными. Погрешность работы ИНС – 0,85 %.

Спиральные проволочные вставки оказывают комбинированное воздействие на поток теплоносителя, что положительно сказывается на теплогидравлических параметрах. Для обучения ИНС использован экспериментальный материал [18, 19].

Результаты тестирования ИНС представлены на рис. 8.




Рис. 8

Как видим (рис. 8, б), в обучающем наборе есть величина, параметры которой следует изучить дополнительно. Погрешность работы ИНС – 1,05 %.

Положительный эффект в случае спиральных выступов достигается за счет закрутки потока спиральными выступами. Для обучения ИНС использован экспериментальный материал [20, 21].

Результаты тестирования ИНС представлены на рис. 9.




Рис. 9

Результаты нейросетевого моделирования по данному типу поверхностных интенсификаторов теплообмена показывают высокую точность предсказания и обучения сети. Погрешность ИНС – 0,84 %.

Применение цилиндрических выемок позволило значительно уменьшить гидравлические потери. Обучающая выборка сформирована по результатам исследований [22–25].

Результаты тестирования ИНС представлены на рис. 10.




Рис. 10

Результаты тестирования ИНС при интенсификации теплообменной поверхности цилиндрическими выемками показывают, что реальные значения тестовой матрицы практически совпадают со спрогнозированными ИНС значениями, а ошибка обучения стремится к нулю. Средняя абсолютная ошибка на обучающем и тестовом наборе стремится к нулю. Погрешность ИНС – 0,9 %.

Таким образом, представлена методика нейросетевого моделирования теплогидравлической эффективности при поверхностной интенсификации теплообмена. Результаты нейросетевого моделирования показывают, что погрешность моделирования в диапазоне 0,5...1,65 % можно считать удовлетворительной, учитывая разброс в выборке данных, связанных с погрешностью базовых экспериментальных данных. Также для практического использования результатов моделирования необходимо разработать аналогичную нейросетевую модель для переходных режимов течения теплоносителя, что будет следующим этапом данного исследования.

СПИСОК ЛИТЕРАТУРЫ

1. Щелчков А.В. Физическое и численное моделирование интенсификации теплообмена поверхностными генераторами вихрей в трактах систем охлаждения: Автореф. дис. ... д-ра техн. наук. Казань, 2017. 67 с.
2. Попов И.А., Щелчков А.В., Яркаев М.З. Теплогидравлические характеристики дискретно-шероховатых труб на переходных режимах течения // Изв. вузов. Авиационная техника. 2013. № 1. С. 61–65.

3. Калинин Э.К. и др. Эффективные поверхности теплообмена. М.: Энергоатомиздат, 1998. 407 с.
4. Закиров С.Г., Каримов К.Ф., Самтаров Т.Х. Применение двухмерной шероховатости для увеличения теплоотдачи вязкой среды // Тр. 2-й Рос. нац. конф. по теплообмену. М.: Изд-во МЭИ, 1998. Т. 6. С. 114–116.
5. Олимпиев В.В. Расчетное и опытное моделирование теплоотдачи и гидросопротивления дискретно шероховатых каналов теплообменного оборудования: Автореф. дис. ... д-ра техн. наук. Казань, 1995. 33 с.
6. Гортышов Ю.Ф. и др. Теплогидравлическая эффективность перспективных способов интенсификации теплоотдачи в каналах теплообменного оборудования. Казань: Изд-во Казан. гос. техн. ун-та, 2009. 531 с.
7. Borisov I. et al. Comparison of Thermo-Hydraulic Characteristics for Two Types of Dimpled Surfaces // Proc. of the ASME Turbo Expo 2004: Power for Land, Sea, and Air, June 14–17, 2004, Vienna, Austria. ASME Paper № GT2004-54204. P. 933–942.
8. Vicente P.G., Garcia A., Viedma A. Heat Transfer and Pressure Drop for Low Reynolds Turbulent Flow in Helically Dimpled Tubes // International Journal of Heat and Mass Transfer. 2002. Vol. 45. Iss. 3. P. 543–553.
9. Щукин А.В. и др. Интенсификация теплообмена при комбинированном охлаждении входной кромки турбинной лопатки // Изв. вузов. Авиационная техника. 2013. № 4. С. 47–50.
10. Ильинков А.В. и др. Интенсификация теплообмена в полях массовых сил, градиента давления, пульсаций скорости и импактных струй // Теплоэнергетика. 2020. № 1. С. 44–52.
11. Щукин А.В. и др. Теплофизика рабочих процессов в охлаждаемых лопатках газовых турбин. Казань: Изд-во КНИТУ-КАИ, 2020. 392 с.
12. Агачев Р.С., Ильинков А.В., Щукин А.В. Теплоотдача при обтекании сферической двояковогнутой выемки // Вестник КГТУ им. А.Н. Туполева. 2001. № 4. С. 12–15.
13. Zhou F. Studies on the Heat/Mass Transfer Characteristics and Fluid Structure in a Square Internal Cooling Channel with Dimpled [Electronical Resource]. URL: https://digitalcommons.lsu.edu/cgi/viewcontent.cgi?article=2193&context=gradschool_theses (дата обращения: 20.11.2020).
14. Бурцев С.А. и др. Экспериментальное исследование характеристик поверхностей, покрытых регулярным рельефом // Наука и образование: научное издание МГТУ им. Н.Э. Баумана. 2013. № 1. С. 263–290.
15. Patil P., Deshmukh P. An Experimental Study of Heat Transfer Enhancement in the Circular Channel with Almond Shape Dimples // IOSR Journal of Mechanical and Civil Engineering. 2014. Vol. 11. Iss. 5 Ver. I. P. 48–57.
16. Ranaware A.G., Bhosale S.Y. A Study of Heat Transfer Enhancement Using V Shaped Dimples on a Flat Plate with Experimentation & CFD // Global Research and Development Journal for Engineering. 2016. Vol. 1. Iss. 4. P. 104–110.
17. Исаев С.А., Леонтьев А.И., Кудрявцев Н.А. Численное моделирование гидродинамики и теплообмена при турбулентном поперечном обтекании «траншеи» на плоской поверхности // Теплофизика высоких температур. 2005. № 1. С. 86–99.
18. Yu Rao et al. Experimental and Numerical Study of Heat Transfer and Flow Friction in Channels with Dimples of Different Shapes // Journal of Heat Transfer. 2015. Vol. 137. Iss. 3. 10 p.
19. Олимпиев В.В. Модифицированная аналогия Рейнольдса для отрывных течений, присоединившихся к стенке // Изв. вузов. Авиационная техника. 2002. № 3. С. 67–69.
20. Garcia A. et al. Enhancement of Laminar and Transitional Flow Heat Transfer in Tubes by Means of Wire Coil Inserts // International Journal of Heat and Mass Transfer. 2007. Vol. 50. Iss. 15-16. P. 3176–3189.
21. Рэинири С., Фэринэ А., Пэглирини Г. Экспериментальное исследование теплообмена и потерь давления при ламинарном течении в трубах со спиральными выступами // Труды университета Пармы. 1995. С. 55–60.
22. Габдрахманов И.Р. и др. Гидродинамика и теплообмен в каналах с выемками цилиндрической формы // Вестник КГТУ им. А.Н. Туполева. 2014. № 4. С. 14–19.
23. Haigermoser C., Scarano F., Onorato M. Investigation of the Flow in a Circular Cavity Using Stereo and Tomographic Particle Image Velocimetry // Experiments in Fluids. 2009. Vol. 46. Iss. 3. P. 517–526.
24. Marsden O., Bogey C., Bailly C. Numerical Investigation of Flow Features and Acoustic Radiation from Round Cavities // Proc. of 16th AIAA/CEAS Aeroacoustics Conference, June 7–9, 2010, Stockholm, Sweden. AIAA 2010-3988. P. 1–13.
25. Халатов А.А., Онищенко В.Н. Гидравлическое сопротивление системы многорядных углублений цилиндрической формы на плоской поверхности // Восточно-Европейский журнал передовых технологий. 2009. № 5 (40). С. 34–36.

Поступила в редакцию 26.11.20
 После доработки 9.12.20
 Принята к публикации 10.12.20

Neural Network Modeling of Thermal-Hydraulic Efficiency of Promising Surface Heat Transfer Intensifiers

K.KH. GIL'FANOV¹ AND R.A. SHAKIROV²

¹ Kazan State Power Engineering University, Kazan

² OOO Gazprom Transgaz Tchaikovsky, Chaykovsky

The technique of neural network modeling of thermal-hydraulic efficiency in the surface intensification of heat exchange equipment is presented. The results of neural network modeling for various surface intensifiers are obtained. Data from experimental studies were used to train an artificial neural network.

Heat transfer, hydraulic resistance, artificial neural network, surface heat transfer intensifiers