

УДК 536.24

ПРОГНОЗИРОВАНИЕ КОЭФФИЦИЕНТА ТЕПЛООТДАЧИ ПРИ КИПЕНИИ
ХЛАДАГЕНТА В ИСПАРИТЕЛЕ ТЕПЛООВОГО НАСОСА С ПОМОЩЬЮ
ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ

И. С. Александров, А. А. Герасимов

PREDICTION OF BOILING HEAT TRANSFER COEFFICIENT OF REFRIGERANT
IN THE EVAPORATOR OF THE HEAT PUMP BY ARTIFICIAL
NEURAL NETWORK

I. S. Alexandrov, A. A. Gerasimov

На основе экспериментальных данных разработана новая модель на базе искусственных нейронных сетей, применяемая для прогнозных расчетов коэффициента теплоотдачи при кипении хладагента в испарителе теплового насоса. Основу обрабатываемого массива экспериментальных данных составили результаты исследования энергетических характеристик теплонасосной установки, выполненного в научно-исследовательской лаборатории «Теплонасосные системы» Московского энергетического института. Эксперимент проводился на учебно-экспериментальном стенде, схема которого приведена в статье. Рабочим телом являлся фреон R134a. На основе указанного массива данных было произведено обучение двухслойной нейронной сети с обратным распространением ошибки по методу Левенберга – Марквардта. Для устранения эффекта переобучения сети параллельно осуществлялись процедуры тестирования и проверки (валидации). В статье представлены результаты сравнения значений коэффициента теплоотдачи, рассчитанных обученной нейронной сетью, с экспериментальными данными. В частности, средняя относительная погрешность описания коэффициента теплоотдачи обученной сетью не превышает 2,6, а средняя квадратичная – 5,84 %, что соответствует погрешности экспериментального определения. Для проверки прогнозных возможностей нейронной сети в статье представлены результаты моделирования коэффициента теплоотдачи в зависимости от различных параметров процесса. Моделирование проводилось в областях параметров, существенно превышающих экспериментально исследованный диапазон. Результаты моделирования показывают правильное физическое поведение коэффициента теплоотдачи, что позволяет сделать вывод о хороших экстраполяционных возможностях обученной нейронной сети. Полученные в данной работе результаты могут быть использованы для проектирования и расчета теплонасосных установок и холодильных машин.

коэффициент теплоотдачи, хладагент, тепловой насос, нейронная сеть

Based on the experimental data the new artificial neural networks model is developed for predicted calculations of heat transfer coefficient of refrigerant in the evaporator of the heat pump. Basis of the array of experimental data was included in the fit-

ting procedure consisting of research results of power characteristics of heat pumps, executed in research laboratory "Heatpump Systems" of the Moscow power institute. Measurements were taken on experimental apparatus which scheme is provided in article. Working substances was refrigerant R134a. Based on the specified experimental data training of a two-layer backpropagation neural network was made. Training of a neural network was provided on a Levenberg - Marquardt method. For elimination of effect of retraining of a network the procedures of testing and validations was made. The results of comparison of the values of heat transfer coefficient calculated by the trained neural network with experimental data are presented in article. The average absolute deviation of heat transfer coefficient calculated using the trained neural network do not exceed 2,6 %, and the root mean square - 5,84 %, that corresponds to an experimental error. For check of predicted opportunities of a neural network the results of modeling of heat transfer coefficient depending on various parameters of process are presented in article. Modeling was carried out in areas of the parameters significantly exceeding experimentally investigated range. Results of modeling show the correct physical behavior of heat transfer coefficient that speaks about good extrapolation opportunities of the trained neural network. The results received in this work can be used for design and calculation of heat pumps and refrigerators.

heat transfer coefficient, refrigerant, heat pump, neural network

ВВЕДЕНИЕ

В последнее время заметно повышенное внимание к новым энергосберегающим технологиям, в том числе к тепловым насосам. Тепловые насосы как технология, позволяющая частично вытеснить органическое топливо и обеспечить теплоснабжение с минимальными затратами первичной энергии, находится в центре внимания при проведении зарубежных и отечественных исследований, одним из важных направлений которых в данной области является изучение теплотехнических характеристик рабочих веществ (хладагентов) для теплонасосных установок, в частности, коэффициента теплоотдачи α .

Однако подобные работы сопряжены с определенными трудностями, связанными с их трудоемкостью и дороговизной, а также с многопараметричностью и нелинейностью зависимости коэффициента теплоотдачи от условий протекания процесса теплопередачи.

Решение указанных проблем - это развитие универсальных подходов в определении теплотехнических характеристик хладагентов, обладающих возможностями прогнозирования. Одним из таких подходов является использование искусственных нейронных сетей, которые в настоящий момент находят широкое применение в различных областях науки и техники.

В последние годы активно используется новый алгоритмический аппарат приближения функций многих переменных с помощью линейных операций и суперпозиций функций одного переменного [1]. Такое приближение осуществляется специальными формальными устройствами – *нейронными сетями*, состоящими из формальных *нейронов*.

Нейрон – преобразовательный элемент, имеющий заданное количество входов (синапсов), на которые поступают входные сигналы x_i , и один выход (аксон), с которого снимается выходной сигнал y . Каждый синапс имеет вес w_i ,

назначаемый каждому входному сигналу x_i . Структура нейрона представлена на рис. 1. Внутри нейрона можно выделить блок суммирования, определяющий взвешенную сумму всех входных сигналов

$$U = \sum_{i=1}^n w_i \cdot x_i \quad (1)$$

и блок функции активации $Y = F(U)$. Таким образом, нейрон функционирует за два такта: 1) суммирование входных сигналов и 2) вычисление Y по функции активации.

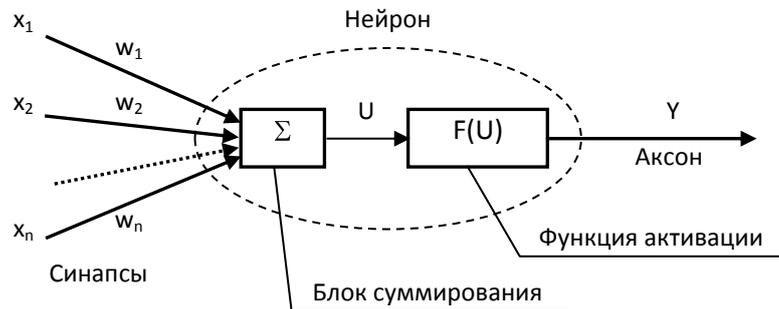


Рис. 1. Структура нейрона
Fig. 1. Structure of neuron

В качестве функций активации используется сигмоидная функция

$$F(U) = \frac{1}{1 + e^{-\alpha U}} \quad (2)$$

Нейроны образуют нейронные сети путем соединения синапсов с аксонами. Наиболее распространенные и хорошо изученные - это многослойные сети, состоящие из следующих слоев нейронов: входного, скрытого и выходного (рис. 2). Нейроны входного слоя имеют только по одному синапсу. Количество нейронов входного слоя соответствует количеству входных переменных сети X . Задачей нейронов этого слоя является только распределение входных сигналов по нейронам скрытого слоя; суммирования и вычисления функции активации в них не происходит. Количество нейронов в скрытом слое может быть различным и часто подбирается экспериментально, но следует учитывать, что недостаточное или избыточное количество нейронов приводит к ухудшению точности аппроксимации.

Данные сети относятся к сетям прямого распространения, поскольку в них входные сигналы последовательно проходят через все нейроны и после преобразований напрямую подаются на выходы. Выходной сигнал y_{ij} каждого j -го нейрона в i -м слое определяется как

$$y_{ij} = F \left(\sum_{k=1}^{n(i-1)} w_{ij}^k \cdot y_{i-1,k} \right) \quad (3)$$

где $n(i)$ – число нейронов в i -м слое.

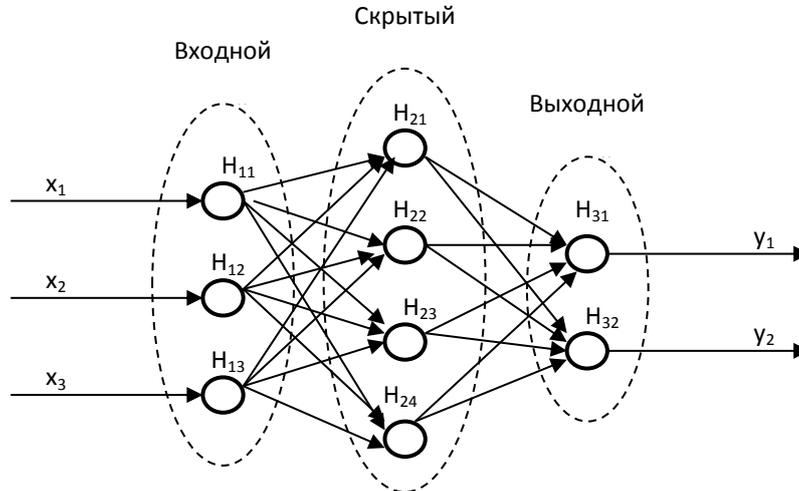


Рис. 2. Слоистая нейронная сеть
Fig. 2. Layered neural network

Нейронные сети являются так называемыми «черными ящиками», аппроксимирующими некоторые функции вида $Y = F(X)$, где Y – вектор выходных переменных, X – вектор входных. Этот процесс заключается в подборе весовых коэффициентов w_{ij} и называется обучением НС. То есть сеть может функционировать в двух режимах:

- эксплуатации, когда на вход подаются сигналы, а на выходе снимаются результаты вычислений;
- обучения, когда происходит корректировка весов таким образом, чтобы выходные сигналы наиболее точно соответствовали желаемым.

От качества обучения зависит точность работы сети в режиме эксплуатации. В данной статье применена нейронная сеть с функциями активации сигмоидного типа. Обучение осуществлялось по правилу обратного распространения с минимизацией ошибки обучения, которая определяется как

$$E = \frac{1}{2} \sum_{i=1}^{N_{\text{оцт}}} (Y_i - Y_{\text{жел.}i})^2, \quad (4)$$

где $Y_{\text{жел}}$ – желаемые значения выходных сигналов (экспериментальные значения).

МОДЕЛЬ НЕЙРОННОЙ СЕТИ

Создание, обучение и моделирование нейронной сети производили в среде программирования MATLAB [2]. Для прогнозирования коэффициента теплоотдачи была создана двухслойная нейронная сеть с обратным распространением ошибки (backpropagation neural network). Архитектура сети представлена на рис. 3.

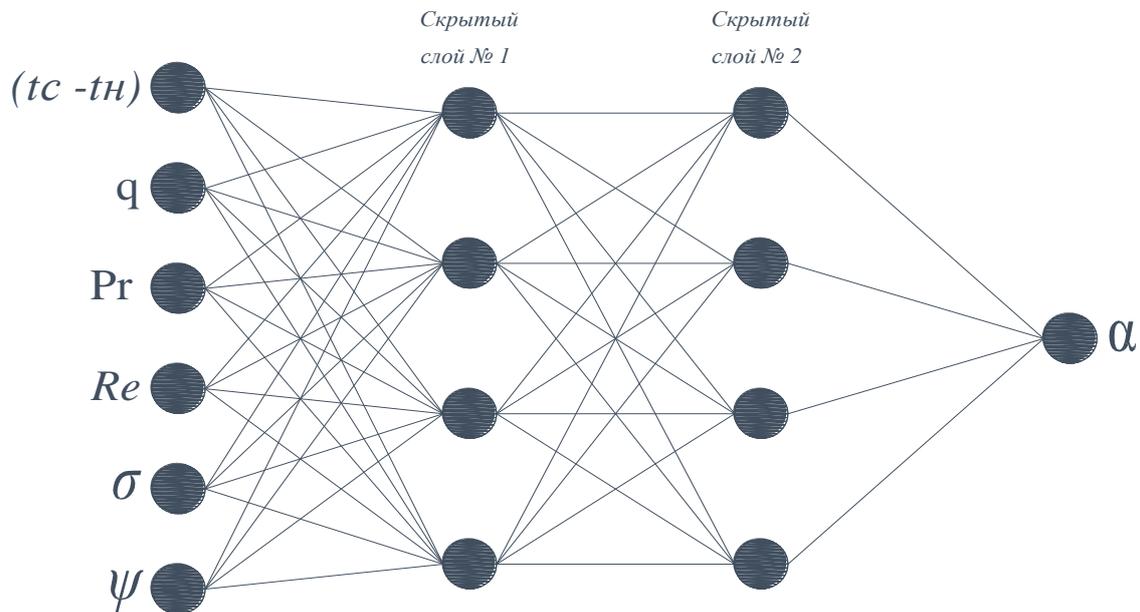


Рис. 3. Архитектура применяемой нейронной сети
 Fig. 3. Architecture of the applied neural network

В данном случае функциональная зависимость для коэффициента теплоотдачи определялась в виде

$$\alpha = f(\Delta t, q, Pr, Re, \sigma, \psi), \quad (5)$$

где $\Delta t = (t_c - t_n)$ - разность между температурами стенки у корня ребра t_c и кипящего фреона; t_n - температурный напор при кипении, °С; q - тепловой поток, Вт/м²; Pr - критерий Прандтля; Re - критерий Рейнольдса; σ - поверхностное натяжение, Н/м; ψ - коэффициент оребрения.

Тестирование предлагаемой модели выполнялось на массиве экспериментальных значений, полученных в научно-исследовательской лаборатории «Теплонасосные системы» Московского энергетического института [3, 4]. Измерения проводились на учебно-экспериментальном стенде (УЭС) «ТН-300», принципиальная схема которого представлена на рис. 4. Основной частью стенда является холодильная машина, рабочим телом которой был фреон R134a.

Кожух 1 испарителя 2 выполнен в виде трубы диаметром 50/43,5 из нержавеющей стали марки 12Х10Н и имеет длину 300 мм. Для определения расхода фреона сконструирован и установлен на всасывающей линии компрессора расходомер 3 калориметрического типа. Пары фреона по всасывающему контуру через емкость - ресивер 7 попадают в компрессор 6. Конденсатор 5 с водяным охлаждением из термостата 4 позволяет устанавливать выбранную температуру конденса-

ции в широком диапазоне температур (от 15 °С до 50 °С). Более подробно конструкция стенда и методика эксперимента описаны в [3].

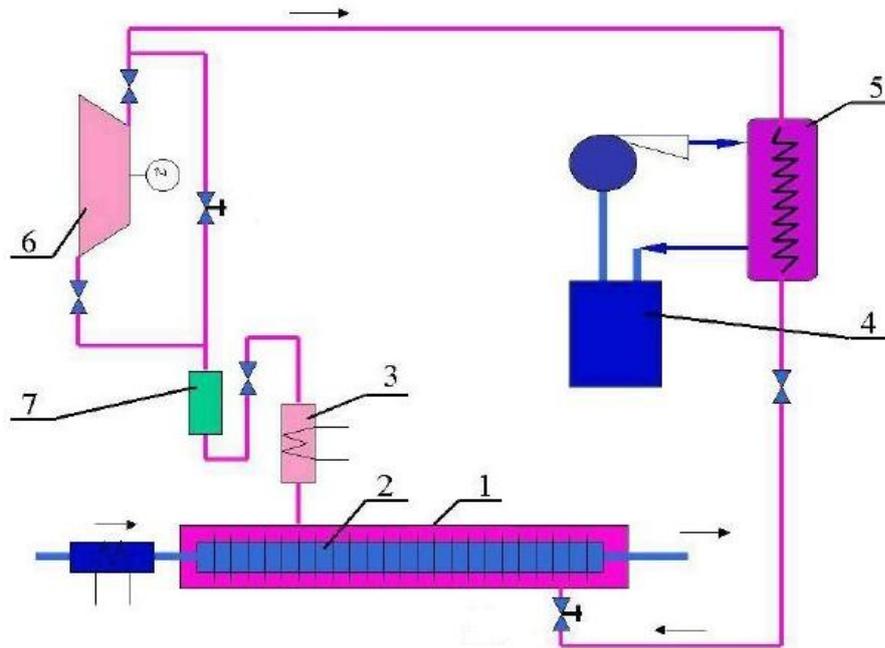


Рис. 4. Принципиальная схема установки «ТН-300»
 Fig. 4. Schematic diagram of the apparatus «ТН-300»

На установке ТН-300 были проведены экспериментальные исследования теплоотдачи при кипении фреона R134a на рельефной теплообменной поверхности с двумя типами оребрения. В результате испытаний УЭС «ТН-300», получены теплотехнические характеристики опытной парокompрессионной теплонасосной установки, на основе которых осуществлялось обучение искусственной нейронной сети.

В качестве обучающей процедуры применялся алгоритм Левенберга – Марквардта [5]. Алгоритм обучения функционирует пошагово, и эти шаги называются эпохами, или циклами. На каждом цикле на вход сети подаются все элементы обучающей последовательности, затем вычисляются выходные значения сети, сравниваются с целевыми значениями и вычисляется функционал ошибки. Значения функционала, а также его градиента используются для корректировки весов, после чего все действия повторяются. Процесс обучения прекращается, когда выполнено заданное количество циклов либо когда ошибка достигнет некоторого малого значения или перестанет уменьшаться. Для устранения эффекта переобучения сети параллельно проводились процедуры тестирования и проверки (валидации). Экспериментальные данные, а также результаты моделирования с помощью обученной сети представлены в таблице.

Средняя относительная погрешность описания используемого массива обученной сетью составляет 2,6, а среднеквадратичная - 5,84 %, что в полной мере соответствует погрешности экспериментальных данных [3].

Таблица. Обучающий массив данных и результаты моделирования нейронной сетью

Table 1. The training array of data and results of modeling by a neural network

$(t_c - t_n),$ °C	$q,$ Вт/м ²	Pr	Re	$\sigma,$ мН/м	Ψ	$\alpha,$ Вт/м ² К (экспери- мент)	$\alpha,$ Вт/м ² К (модель)
1.25	1090	0.83133	578.4604	12.582	2.75	890	793.8292
1.45	2250	0.83133	1190.6176	12.582	2.75	550	623.2108
1.61	3050	0.83133	1614.6347	12.582	2.75	1890	1873.859
1.65	3550	0.83133	1881.4005	12.582	2.75	2150	2133.149
1.81	4200	0.83133	2226.7919	12.582	2.75	2320	2383.409
2	5080	0.83133	2690.1219	12.582	2.75	2540	2539.554
1.09	1130	0.83431	599.6104	11.73	2.75	1040	1061.329
1.33	2100	0.83431	1108.4541	11.73	2.75	1580	1542.848
1.4	3150	0.83431	1664.0564	11.73	2.75	2250	2254.428
1.51	3860	0.83431	2038.1253	11.73	2.75	2560	2573.472
1.59	4350	0.83431	2299.4234	11.73	2.75	2740	2740.358
1.79	5190	0.83431	2742.2549	11.73	2.75	2900	2842.381
0.82	1120	0.8423	597.4197	10.474	2.75	1370	1375.382
1.07	2050	0.8423	1090.8243	10.474	2.75	1920	1909.2
1.22	2850	0.8423	1514.8856	10.474	2.75	2340	2344.93
1.34	3500	0.8423	1858.9354	10.474	2.75	2610	2695.49
1.41	4400	0.8423	2341.6719	10.474	2.75	3120	3103.866
1.65	5350	0.8423	2853.7459	10.474	2.75	3240	3246.494
0.81	1290	0.83133	665.5103	12.582	8.49	1580	1577.268
0.98	2000	0.83133	1036.1743	12.582	8.49	2040	1456.631
1.15	3050	0.83133	1575.3219	12.582	8.49	2650	2510.644
1.28	3750	0.83133	1940.3697	12.582	8.49	2930	2928.183
1.39	4500	0.83133	2327.8821	12.582	8.49	3240	3268.977
1.4	5000	0.83133	2586.2236	12.582	8.49	3570	3553.238
0.58	1250	0.83431	646.3690	11.73	8.49	2160	2178.093
0.91	2490	0.83431	1284.4865	11.73	8.49	2740	2829.724
1.04	3180	0.83431	1639.3019	11.73	8.49	3060	3061.155
1.11	3780	0.83431	1952.8596	11.73	8.49	3410	3307.577
1.2	4450	0.83431	2293.9224	11.73	8.49	3710	3702.706
1.31	5150	0.83431	2656.9892	11.73	8.49	3930	4134.302
0.59	1390	0.8423	720.1041	10.474	8.49	2360	2352.65
0.77	2250	0.8423	1162.8348	10.474	8.49	2920	2920.348
0.94	3110	0.8423	1597.5643	10.474	8.49	3310	3362.641
1	3620	0.8423	1874.9377	10.474	8.49	3620	3556.335
1.16	4350	0.8423	2250.9920	10.474	8.49	3750	3795.893
1.25	5120	0.8423	2648.3829	10.474	8.49	4100	4092.952

На рис. 5 - 8 показан характер поведения коэффициента теплоотдачи в зависимости от изменения различных параметров процесса. Эти результаты получены моделированием с помощью обученной нейронной сети для проверки ее прогнозных возможностей.

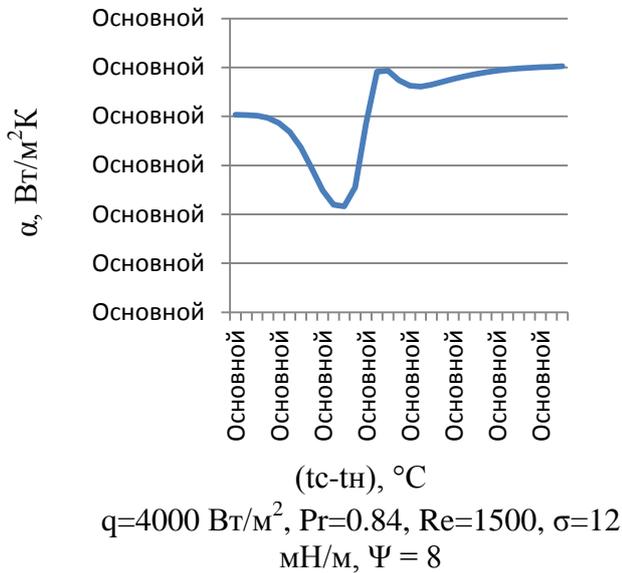


Рис. 5. Зависимость коэффициента теплоотдачи от температурного напора
 Fig. 5. Dependence of heat transfer coefficient on a temperature

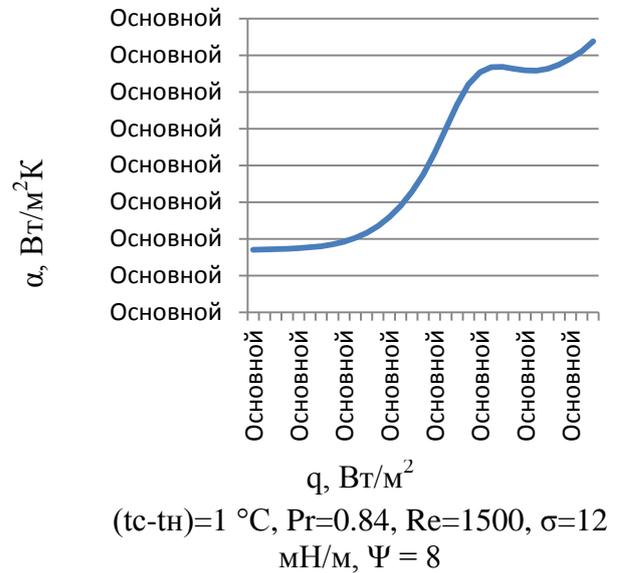


Рис. 6. Зависимость коэффициента теплоотдачи от теплового потока
 Fig. 6. Dependence of heat transfer coefficient on a heat flux

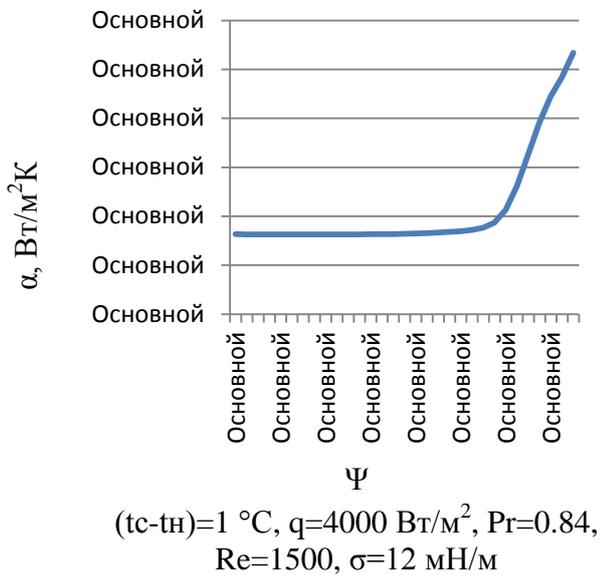


Рис. 7. Зависимость коэффициента теплоотдачи от коэффициента оребрения
 Fig. 7. Dependence of heat transfer coefficient on a fins coefficient

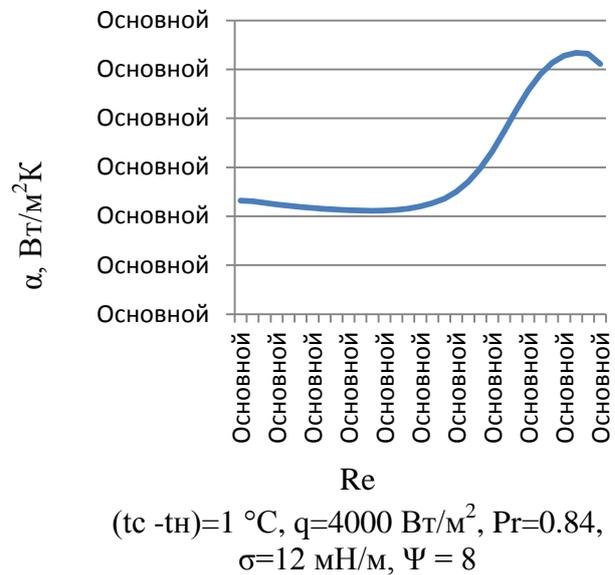


Рис. 8. Зависимость коэффициента теплоотдачи от числа Рейнольдса
 Fig. 8. Dependence of heat transfer coefficient on a Reynolds number

На рис. 5 изображена зависимость коэффициента теплоотдачи от температурного напора. Подобный график в научно-технической литературе называют

"кривой кипения". На этой кривой хорошо видны несколько интервалов, соответствующих различным режимам теплоотдачи. Начальный режим характеризует пузырьковый режим кипения, далее наблюдается некоторое снижение, характерное для переходного режима. При дальнейшем увеличении перегрева интенсивность теплоотдачи, достигнув минимума, снова начинает возрастать в области пленочного режима кипения. Аналогичная картина наблюдается на рис. 6, где представлена зависимость коэффициента теплоотдачи от теплового потока. Рис. 7 показывает характер изменения коэффициента теплоотдачи при увеличении коэффициента оребрения. Из рисунка видно, что возрастание до определенного значения коэффициента Ψ не приводит к существенному увеличению коэффициента α . Резкое возрастание коэффициента α и, соответственно, повышение эффективности процесса теплопередачи происходит, начиная со значений коэффициента Ψ порядка 7,5-8,0. Этот факт может быть использован при расчете и конструировании кожухотрубных испарителей тепловых насосов. Рис. 8 отражает зависимость коэффициента теплоотдачи от числа Рейнольдса. На рисунке хорошо видна область автомодельности со слабой зависимостью коэффициента α от числа Re . За пределами этой области коэффициент α начинает возрастать.

ЗАКЛЮЧЕНИЕ

Таким образом, разработана модель на базе искусственных нейронных сетей для прогнозных расчетов коэффициента теплоотдачи при кипении. На основе вышесказанного можно сделать вывод о том, что предлагаемая модель не только описывает имеющиеся экспериментальные данные с точностью, близкой к экспериментальной, но и физически правильно передает зависимость коэффициента теплоотдачи от различных параметров процесса за пределами экспериментально исследованного диапазона.

СПИСОК ИСПОЛЬЗОВАННЫХ ЛИТЕРАТУРНЫХ ИСТОЧНИКОВ

1. Колмогоров, А. . О представлении непрерывных функций нескольких переменных в виде суперпозиции непрерывных функций одного переменного / А. Н. Колмогоров // Доклады АН СССР. - 1957. - Т. 114, № 5. – С. 953-956.
2. Медведев, В. С. Нейронные сети. MATLAB 6 / В. С. Медведев, В. Г. Потемкин; под общ. ред. В. Г. Потемкина. – Москва: Диалог МИФИ, 2002. – 496 с.
3. Сухих, А. А. Исследование термодинамических свойств и теплотехнических характеристик фторорганических рабочих веществ: дис. ... докт. техн. наук / А. А. Сухих.- Москва, 2012. – 386 с.
4. Соколов, Е. Ю. Лабораторный стенд и комплекс программ для исследования энергетических характеристик теплонасосной установки / Е. Ю. Соколов, Д. В. Сиденков, А. А. Сухих // 8-я международная научно-техническая конференция студентов и аспирантов: тезисы докладов (28.02-1.03. 2002 г) /МЭИ. – Москва, 2002.- Т. 3. - С.130.
5. Hagan M.T., Menhaj M. Training feedforward networks with the Marquardt algorithm // IEEE Transactions on Neural Networks. – 1994. – Vol. 5, №6. – P. 989-993.

REFERENCES

1. Kolmogorov A.N. *O predstavlenii nepreryvnykh funktsiy neskol'kikh peremennykh v vide superpozitsii nepreryvnykh funktsiy odnogo peremennogo* [On presentation of continuous functions of several variables in the form of continuous functions of one variable]. Doklady AN SSSR [Reports of AS USSR]. 1957, vol. 114, no. 5, pp. 953-956.
2. Medvedev V. S., Potemkin V. G. *Neyronnye seti. MATLAB 6* [Neural networks. MATLAB 6]. Moscow, Dialog MIFI, 2002, 496 p.
3. Sukhikh A. A. *Issledovanie termodinamicheskikh svoystv i teplotekhnicheskikh kharakteristik ftororganicheskikh rabochikh veshchestv. Dis. dokt. tekhn. nauk.* [Study of thermodynamic properties and burning characteristics of fluoroorganic working substances. Dis. dr. engine. sci.]. Moscow, 2012, 386 p.
4. Sokolov E. Yu., Sidenkov D.V., Sukhikh A.A. *Laboratornyy stend i kompleks programm dlya issledovaniya energeticheskikh kharakteristik teplonasosnoy ustanovki* [Laboratory bench and program system for studying energy characteristics of heat pump system]. *Tezisy dokladov 8-oy mezhdunarodnoy nauchno-tekhnicheskoy konferentsii studentov i aspirantov 28.02-1.03. 2002 g.* [Abstracts of the 8th international scientific students conference 28.02-1.03. 2002]. Moscow, MEI, vol. 3, 130 p.
5. Hagan M.T., Menhaj M. Training feedforward networks with the Marquardt algorithm. *IEEE Transactions on Neural Networks*, 1994, vol. 5, no. 6, pp. 989-993.

ИНФОРМАЦИЯ ОБ АВТОРАХ

Александров Игорь Станиславович – Калининградский государственный технический университет; кандидат технических наук, доцент кафедры «Теплогазоснабжение и вентиляция»; e-mail: alexandrov_kgrd@mail.ru

Alexandrov Igor Stanislavovich – Kaliningrad State Technical University; Candidate of Technical Sciences, Associate Professor of the Department «Heat and gas supply and ventilation»; e-mail: alexandrov_kgrd@mail.ru

Герасимов Анатолий Алексеевич – Калининградский государственный технический университет; доктор технических наук, профессор, заведующий кафедрой «Теплогазоснабжение и вентиляция»; e-mail: aager_kstu@mail.ru

Gerasimov Anatoly Alekseevich – Kaliningrad State Technical University; Doctor of Technical Sciences, Professor, Head of the Department «Heat and gas supply and ventilation»; e-mail: aager_kstu@mail.ru