DOI: 10.17122/ntj-oil-2019-2-97-106

УДК 004.032

С.Н. Костарева, И.Р. Байков, О.В. Смородова, С.А. Киселева (Уфимский государственный нефтяной технический университет, г. Уфа, Российская Федерация)

НЕЙРОСЕТЕВОЕ МОДЕЛИРОВАНИЕ ЗАГРЯЗНЕНИЯ АТМОСФЕРНОГО ВОЗДУХА КОМПРЕССОРНЫМИ СТАНЦИЯМИ МАГИСТРАЛЬНЫХ ГАЗОПРОВОДОВ

Svetlana N. Kostareva, Igor R. Baikov, Olga V. Smorodova, Sofia A. Kiseleva
(Ufa State Petroleum Technological University, Ufa, Russian Federation)

NEURAL NETWORK MODELING OF ATMOSPHERIC AIR POLLUTION BY MAIN GAS PIPELINES COMPRESSOR STATIONS

Введение

Оперативный временной контроль основных параметров эксплуатации газоперекачивающих агрегатов (ГПА) компрессорных станций является залогом высокого качества оценки текущего состояния системы. При этом существующие стационарные измерительные устройства могут быть эффективно агрегированы с расчетными моделями прогнозирования динамики технологического процесса магистрального транспорта газа.

Цели и задачи

Известно, что количество выбросов оксидов азота и углерода с выхлопными газами ГПА коррелирует с процессами старения и износа агрегатов. В статье решается актуальная задача развития методов моделирования количества выбросов как аргумента технического состояния ГПА.

Методы

База данных для решения поставленной задачи может быть обеспечена стационарной системой контроля основных показателей ГПА, находящихся в режиме компримирования магистрального газа.

Background

An important role in solving the problems of technical diagnostics is assigned to prompt, reliable monitoring of the operational parameters of the process equipment. At the same time, the existing information-measuring systems should be supplemented by computational methods of technological parameters of operation of gas pumping units (GPU).

Aims and Objectives

It is known that the amount of emissions of nitrogen oxides and carbon with exhaust gases of GPU correlates with the processes of aging and deterioration of aggregates. The task of developing computational methods for modeling the amount of emissions by GPU as an argument of the GPU technical state is relevant.

Methods

The database for solving the task can be provided with a permanent system for measuring the technological parameters of operating units.

На практике для оценки осложнения экологического состояния окружающей природной среды применяются автоматизированные системы мониторинга. Однако высокая стоимость подобного оборудования на нефтегазовом рынке препятствует их повсеместному применению.

Показано, что содержание NO_x и CO в продуктах сгорания топливного газа ГПА имеет значимую корреляционную связь с температурой газов, частотой вращения и температурой наружного воздуха на входе в компрессор. Этот факт обосновывает необходимость многопараметрического моделирования концентраций оксидов азота и углерода. Решение практических задач техногенного характера весьма продуктивно в пределах реализации нейросетевой модели.

Результаты

На основе значений основных технологических параметров ГПА построены нейронные сети для оценки выбросов оксидов азота и углерода от агрегатов ГПУ-10 «Волна» с погрешностью менее 7 %.

In world practice, automated monitoring systems are used to control emissions of harmful substances. However, the high cost of such equipment in the oil and gas market prevents their widespread use.

It is shown that the concentrations of nitrogen and carbon oxides in the GPU exhaust gases have a significant correlation with the temperature of the gases, the rotation frequency and the air temperature at the entrance to the axial compressor. This fact proves the need for multi-parameter modeling to determine the concentration of nitrogen oxides and carbon. The solution of practical important problems of complex technological processes is recommended within the neural network model implementation.

Results

Based on the values of the main technological parameters of the GPU, neural network models for estimating emissions of nitrogen oxides and carbon from the GPU-10 Volna aggregates with an error of less than 7 % were constructed.

Ключевые слова: технологический параметр; газоперекачивающий агрегат; выбросы в атмосферу; нейронная сеть; сигмоид

Key words: technological parameter; gas pumping unit; air emissions; neural network; sigmoid

Транспорт природного газа от месторождений к потребителям ведется компримированием центробежными компрессорами (ЦБК) [1]. Приводом ЦБК в системе трубопроводного транспорта ПАО «Газпром» являются в основном газотурбинные установки (ГТУ) - стационарные, авиационные и судовые (рисунок 1) - общим числом более 3000 агрегатов [2]. Существенная доля газоперекачивающих аппаратов (ГПА) была выпущена в середине XX века [3]. Нарботка около 8 % ГПА соответствует предельно допустимому периоду эксплуатации - более 100 тыс. моточасов, 45 % - 50-100 тыс. моточасов.

В основном интенсивное старение агрегатов вызывается эксплуатацией ГПА вне оптимального режима, низким качеством проведения монтажа и ремонта основного и вспомогательного оборудования, подготовки технологических жидкостей для агрегатов - воды, масла, газа и пр. [4]. Наиболее распространенная - параметрическая - диагностика газоперекачивающего оборудования в качестве основных показателей использует уровень вибрации подшипниковых узлов, виброскорость их колебаний, температуру и давление рабочего тела, коэффициент полезного действия ГПА и пр.

Рисунок 1. Распределение ГПА по типам

Наиболее распространенная - параметрическая - диагностика газоперекачивающего оборудования в качестве основных показателей использует уровень вибрации подшипниковых узлов, виброскорость их колебаний, температуру и давление рабочего тела, коэффициент полезного действия ГПА и пр.

При этом степень адекватности оценки технического состояния газового двигателя не превышает 30 % [5], соответствующих этапу перехода дефекта в физическое разрушение узлов агрегата. Вместе с тем определение уровня надежности при только зарождающемся дефекте, когда аварийный отказ ГПА еще может быть предотвращен, является критически необходимым [6]. Исследование [1] показало, что фактическое техническое состояние узлов газоперекачивающих агрегатов проявляется в изменениях состава выхлопных газов газовой турбины. Поэтому в качестве дополнительного метода оценки технического состояния ГПА предлагается разработка модели его идентификации по содержанию NO_x и CO в уходящих газах [7].

В настоящее время контроль состава выбросов проводится периодически, не чаще 1 раза в два месяца. Поэтому разработка моделей с учетом реальных факторов, влияющих на состав выхлопных газов, является крайне актуальной. Адекватность результатов моделирования возрастает с

расширением базы текущих параметров эксплуатации ГПА [8].

Создание многопараметрических нелинейных моделей наиболее продуктивно реализуемо с использованием нейронных сетей (НС) [9-12]. Определяющим выбор способа моделирования фактором является исходная нелинейность нейронных сетей. Этот нетривиальный прикладной инструмент позволяет воспроизводить сложные закономерности техники и технологии.

Первоначально нейронные сети использовались в качестве вычислительных алгоритмов для имитации биологических процессов [13]. Нейронная техногенная сеть разрабатывается по аналогии - совокупность нейроподобных элементов определенным образом соединены друг с другом и внешней средой связями с весовыми коэффициентами [14, 15].

Нейронные сети имеют следующие достоинства по сравнению с прочими методами разработки уравнений регрессии:

- настройка алгоритмом обучения;
- формирование адекватного прогноза.

В качестве базы данных для моделирования использованы значения концентраций NO_x и CO в уходящих газах ГПА и комплекса основных эксплуатационных показателей агрегатов стационарных измерительных систем за период около 4 лет.

Цель нейросетевого моделирования - построение многопараметрических нелинейных моделей взаимосвязи концентраций NO_x и CO и технологических параметров ГПА [16].

При отборе входных аргументов были проанализированы параметры работы ГПА - температуры и давления всех потоков воздуха и продуктов сгорания, частота вращения роторов всех цилиндров газовой турбины, осевого компрессора и нагнетателя магистрального газа. Анализ состоял в

определении тесноты корреляционной связи основных параметров ГПА с содержанием NO_x и CO в продуктах сгорания топливного газа после газовых турбин (рисунок 2).

В результате оценки уровня значимости полученных коэффициентов в качестве входных переменных для нейросетевого моделирования были отобраны наиболее тесно коррелирующие - 6 показателей (таблица 1). Таким образом, было установлено 6-мерное пространство определяющих признаков [17].

Рисунок 2. Результаты корреляционного анализа показателей эксплуатации ГПА

Таблица 1. Перечень входных переменных нейронной сети

№	Параметры	Обозначения	Единица измерения
1	Температура воздуха на входе в осевой компрессор (ОК)	$T_{\text{ок}}$	$^{\circ}\text{C}$
2	Температура продуктов сгорания за турбиной высокого давления (ТВД)	$T_{\text{твд}}$	$^{\circ}\text{C}$
3	Частота вращения компрессора высокого давления (КВД)	$N_{\text{квд}}$	об/мин
4	Частота вращения компрессора низкого давления (КНД)	$N_{\text{кнд}}$	об/мин
5	Частота вращения силовой турбины	$N_{\text{ст}}$	об/мин
6	Абсолютное давление воздуха за КВД	$P_{\text{ок}}$	кг/см^2

В качестве выходных переменных приняты концентрации оксида углерода C_{CO} и оксидов азота C_{NOx} .

Поиск оптимальной архитектуры нейросети сводится к оценке минимального числа нейронов и достаточных для решения связей между ними [18].

Принцип принятия решения состоит в том, что при отсутствии каких-либо специальных указаний предпочтение отдается более простой конфигурации сети [19, 20].

Идентификация оптимальной нейронной сети была реализована многократной разработкой и тестированием сетей различной конфигурации - всего около 80 вариантов. Нейронная сеть - 6 входных переменных, 1 выходная переменная, 8 нейронов - показала оптимальные результаты при контрольном тестировании.

Модель нейрона выражается закономерностью вида:

$$S = \sum_{i=1}^m w_i \cdot x_i$$

$$y = f(S),$$

где w_i - весовой коэффициент i -го входного сигнала;

x_i - i -ый входной сигнал;

m - число входов нейрона;

f - функция активации;

S - результат суммирования;

y - выходной сигнал нейрона.

В качестве функции активации принята нелинейная сигмоидальная логистическая функция:

$$f(S) = \frac{1}{1 + e^{-as}},$$

где a - постоянная величина модели.

Функционирование нейронной сети определяется величиной весовых коэффициентов каждого входного сигнала

w_i .

Идентификация их оптимальных величин является результатом обучения сети элементами представительной обучающей выборки (рисунок 3).

В настоящее время используются несколько алгоритмов обучения нейронных сетей [10]: алгоритм сопряженных градиентов; обратное распространение ошибки прогнозирования; алгоритм квази-Ньютоновский, псевдообратный; обучение Кохонена, Левенберга-Маркара; векторный квантователь. В работе для обучения сети использован один из самых распространенных алгоритмов - алгоритм обратного распространения ошибки, который используется с целью минимизации среднеквадратического отклонения модельного выхода нейронной сети от значения обучающего примера.

Минимизируемой целевой функцией в процессе построения нейронной сети является значение интегральной среднеквадратической ошибки:

$$E(w) = \sum_{j=1}^n (y_j - (C_{CO})_j)^2,$$

где y_j - расчетное содержание СО для j -го примера из обучающей выборки;

$(C_{CO})_j$ - фактическое содержание СО в входящих газах ГПА.

Среднеквадратическая ошибка ($\bar{E}$) при обучении нейронной сети определяется следующим образом:

$$\bar{E}(w) = \sqrt{\frac{\sum_{j=1}^n (y_j - (C_{CO})_j)^2}{n-1}},$$

где n - емкость обучающей выборки.

Корректировка весовых коэффициентов необходима в случае значительной ошибки модельного выходного сигнала. Для этого используют частный дифференциал отклонения выхода сети от требуемого значения:

$$\Delta w_i = -p \frac{\partial E}{\partial w_i},$$

где p - характеристика эффективности настройки сети, $0 < p < 1$.

Обучение ведется пошаговым образом. Каждый шаг реализуется предъявлением сети обучающих примеров.

С учетом значений смоделированных сигналов на выходе сети определяется ошибка, по которой корректируются веса межнейронных связей для повышения адекватности моделирования.

Обучение признается завершенным при достижении ошибкой заданного малого значения или выходом величины ошибки на

минимальный уровень асимптотическим образом.

В качестве примера на рисунке 4 показаны результаты обучения нейронной сети для моделирования содержания СО в уходящих газах ГПА на начальном, промежуточном и заключительном этапах создания модели.

При дальнейшем продолжении обучения ошибка модели вышла на асимптотическое значение $1,144 \text{ мг/нм}^3$, что свидетельствует об удовлетворительном результате обучения нейронной сети.

Тестирование полученных моделей на контрольной выборке, непересекающейся с обучающей, показало среднеквадратическую ошибку расчета $C_{\text{CO}} - 1,202 \text{ мг/нм}^3$, C_{NOx} - около 1 мг/нм^3 (рисунок 5).

Рисунок 3. Архитектура обучения сети

а) ошибки моделирования по обучающим примерам

б) среднеквадратическая ошибка по этапам моделирования

Рисунок 4. Погрешность моделирования концентрации СО

а) оксид углерода

б) оксиды азота

Рисунок 5. Результаты тестирования нейросетевых моделей выбросов загрязняющих веществ в атмосферу после ГПУ-10 «Волна»

Выводы

На основе значений основных технологических параметров ГПА построены нейросетевые модели определения выбросов оксидов азота и углерода от агрегатов ГПУ-10 «Волна».

Полученные модели позволяют диагностировать техническое состояние газоперекачивающих агрегатов на текущем режиме работы по содержанию в выхлопных газах оксидов углерода и азота с погрешностью менее 7 %.

Список литературы

1. Костарева С.Н. Совершенствование методов диагностирования технического состояния газоперекачивающих агрегатов на основе данных производственного мониторинга: дисс. ... канд. техн. наук. Уфа: УГНТУ, 2002. 163 с.
2. Байков И.Р., Китаев С.В., Шаммазов И.А. Перспективы энергоресурсосбережения в условиях длительно эксплуатируемой газотранспортной системы // Транспорт и хранение нефтепродуктов и углеводородного сырья. 2012. № 4. С. 9-13.
3. Байков И.Р., Китаев С.В., Талхин С.Р. Эксплуатация энергомеханического оборудования в современных условиях // Нефтегазовое дело. 2007. Т. 5. № 1. С. 159-162.
4. Иванов Э.С. Особенности моделирования режимов работы газоперекачивающих агрегатов компрессорных станций магистрального транс-

References

1. Kostareva S.N. *Sovershenstvovanie metodov diagnostirovaniya tekhnicheskogo sostoyaniya gazoperekachivayushchikh agregatov na osnove dannykh proizvodstvennogo monitoringa: diss...kand. tekhn. nauk.* [Improvement of Methods for Diagnosing the Technical Condition of Gas Pumping Units on the Basis of Production Monitoring Data: Cand. Engin. Sci. Diss.]. Ufa, USPTU Publ., 2002. 163 p. [in Russian].
2. Baikov I.R., Kitaev S.V., Shammazov I.A. *Perspektivy energoresursosberezheniya v usloviyakh dlitel'no ekspluatiruemoi gazotransportnoi sistemy* [Prospects of Energy Resource Saving in The Conditions of Long-Term Operated Gas Transportation System] *Transport i khraneniye nefteproduktov i uglevodorodnogo syr'ya – Transport and Storage of Oil Products and Hydrocarbons*, 2012, No. 4, pp. 9-13. [in Russian].

порта газа в современных условиях эксплуатации // Электронный научный журнал «Нефтегазовое дело». 2012. № 5. С. 99-123. URL: http://ogbus.ru/files/ogbus/authors/IvanovES/IvanovES_2.pdf (дата обращения: 25.12.2018).

5. Байков И.Р., Смородова О.В., Костарева С.Н. Оценка технического состояния ГКУ с помощью вибродиагностики // Газовая промышленность. 2001. № 4. С. 39-41.

6. Байков И.Р., Китаев С.В., Смородов Е.А., Гольянов А.И. Уточнение методики определения технического состояния газоперекачивающих агрегатов // Известия высших учебных заведений. Проблемы энергетики. 2001. № 3-4. С. 3-7.

7. Байков И.Р., Смородова О.В., Костарева С.Н. Прогностическая модель эмиссии вредных веществ в выхлопных газах ГТУ // Известия высших учебных заведений. Проблемы энергетики. 2004. № 1-2. С. 122-128. URL: https://elibrary.ru/download/elibrary_20213850_21794869.pdf (дата обращения: 25.12.2018).

8. Байков И.Р., Китаев С.В., Фарухшина Р.Р. Определение показателей энергоэффективности газоперекачивающих агрегатов с применением нейронных сетей // Электронный научный журнал «Нефтегазовое дело». 2015. № 1. С. 141-152. URL: http://ogbus.ru/files/ogbus/issues/1_2015/ogbus_1_2015_p141-152_BaikovIR_ru.pdf (дата обращения: 25.12.2018).

9. Байков И.Р., Китаев С.В., Шаммазов И.А. Применение нейронных сетей для прогнозирования добычи углеводородного сырья // Известия высших учебных заведений. Нефть и газ. 2005. № 3. С. 60-64. URL: https://elibrary.ru/download/elibrary_24639555_36320168.pdf (дата обращения: 25.12.2018).

10. Осовский С. Нейронные сети для обработки информации: пер. с польск. / Перевод И.Д. Рудинского. М.: Финансы и статистика, 2004. 344 с.

11. Каменев А.С., Королев С.Ю., Сокотущенко В.Н. Нейромоделирование как инструмент интеллектуализации энергоинформационных сетей. М.: ИЦ «Энергия», 2012. 124 с.

12. Алексеев Д.В. Приближение функций нескольких переменных нейронными сетями // Фундаментальная и прикладная математика. 2009. Т. 15. № 3. С. 9-21. URL: https://elibrary.ru/download/elibrary_12996342_40485360.pdf (дата обращения: 25.12.2018).

13. Funahashi K. On the Approximate Realization of Continuous Mappings by Neural Networks // Neural Networks. 1989. Vol. 2, No. 3. P. 183-192.

14. Hornik K., Stinchcombe M., White H. Multilayer Feedforward Networks are Universal Approximators // Neural Networks. 1989. Vol. 2, No. 5. P. 359-366.

15. White H., Gallant A.R., Hornik K., Stinchcombe M., Wooldridge J. Artificial Neural Networks: Approximation and Learning Theory. Cambridge, MA: Blackwell, 1992.

16. R. Yager L. Zadeh. (Eds.) Fuzzy Sets, Neural Networks and Soft Computing. Van Nostrand Reinhold. New York, 1994.

3. Baikov I.R., Kitaev S.V., Talkhin S.R. Ekspluatatsiya energomekhanicheskogo oborudovaniya v sovremennykh usloviyakh [Operation of Power Mechanical Equipment in Modern Conditions]. *Neftegazovoe delo - Petroleum Engineering*, 2007, Vol. 5, No. 1, pp. 159-162. [in Russian].

4. Ivanov E.S. Osobennosti modelirovaniya rezhimov raboty gazoperekachivayushchikh agregatov kompressornykh stantsii magistral'nogo transporta gaza v sovremennykh usloviyakh ekspluatatsii [Features of Modeling of Operating Modes of Gas Pumping Units of Compressor Stations of Main Gas Transport in Modern Operating Conditions]. *Elektronnyi nauchnyi zhurnal «Neftegazovoe delo» - Electronic Scientific Journal «Oil and Gas Business»*, 2012, No. 5, pp. 99-123. [in Russian]. Available at: http://ogbus.ru/files/ogbus/authors/IvanovES/IvanovES_2.pdf (accessed 25.12.2018). [in Russian].

5. Baikov I.R., Smorodova O.V., Kostareva S.N. Otsenka tekhnicheskogo sostoyaniya GKU s pomoshch'yu vibrodiagnostiki [Assessment of the Technical Condition of the Civil Code with Diagnostics]. *Газовая промышленность* - *Gas Industry*, 2001, No. 4, pp. 39-41. [in Russian].

6. Baikov I.R., Kitaev S.V., Smorodov E.A., Gol'yanov A.I. Utochnenie metodiki opredeleniya tekhnicheskogo sostoyaniya gazoperekachivayushchikh agregatov [Clarification of Methods for Determining the Technical Condition of Gas Pumping Units]. *Izvestiya vysshikh uchebnykh zavedenii. Problemy energetiki. - Proceedings of the Higher Educational Institutions. Energy Sector Problems*, 2001, No. 3-4, pp. 3-7. [in Russian].

7. Baikov I.R., Smorodova O.V., Kostareva S.N. Prognosticheskaya model' emissii vrednykh veshchestv v vykhlopnykh gazakh GTU [Prognostic Model of Emission of Harmful Substances in Exhaust Gases of Gas Turbines]. *Izvestiya vysshikh uchebnykh zavedenii. Problemy energetiki. - Proceedings of the Higher Educational Institutions. Energy Sector Problems*, 2004, No. 1-2, pp. 122-128. Available at: https://elibrary.ru/download/elibrary_20213850_21794869.pdf (accessed 25.12.2018). [in Russian].

8. Baikov I.R., Kitaev S.V., Farukhshina R.R. Opredelenie pokazatelei energoeffektivnosti gazoperekachivayushchikh agregatov s primeneniem neuronnykh setei [Determination of Energy Efficiency Indicators of Gas Pumping Units Using Neural Networks]. *Elektronnyi nauchnyi zhurnal «Neftegazovoe delo» - Electronic Scientific Journal «Oil and Gas Business»*, 2015, No. 1, pp. 141-152. Available at: http://ogbus.ru/files/ogbus/issues/1_2015/ogbus_1_2015_p141-152_BaikovIR_ru.pdf (accessed 25.12.2018). [in Russian].

9. Baikov I.R., Kitaev S.V., Shammazov I.A. Primenenie neuronnykh setei dlya prognozirovaniya dobychi uglevodorodnogo syr'ya [Application of Neural Networks for Forecasting Hydrocarbon Production]. *Izvestiya vysshikh uchebnykh zavedenii. Neft' i gaz. - Proceedings of Higher Educational Establishments. Oil and Gas*, 2005, No. 3, pp. 60-64. Available

17. Mohamad H. *Fundamentals of Artificial Neural Networks*. Cambridge, MIT Press, 1995.

18. Winograd S., Cowan J.D. *Reliable Computation in the Presence of Noise*. Cambridge, MIT Press, 1963. 247 p.

19. Rosenblatt F. The Perceptron: A Probabilistic Model for Information Storage and Organization in The Brain // *Psychological Review*. 1958. No. 65. P. 386-408.

20. Widrow B. Generalization and Information Storage in Networks of Adaline «Neurons» // Washington, D.C.: Sparta, 1962. P. 435-461.

at: https://elibrary.ru/download/elibrary_24639555_36320168.pdf (accessed 25.12.2018). [in Russian].

10. Osovskii S. *Neironnye seti dlya obrabotki informatsii: Per. s pol'sk. Perevod I.D. Rudinskogo* [Neural Networks for Information Processing: Transl. from Polish. Interpr. by I.D. Rudinsky]. Moscow, Finance and Statistics, 2004. 344 p. [in Russian].

11. Kamenev A.S., Korolev S.Yu., Sokotushchenko V.N. *Neiromodelirovanie kak instrument intellektualizatsii energoinformatsionnykh setei* [Neuromodulatory as an Instrument of Intellectualization, Energy and Information Networks]. Moscow, ITS Energy, 2012. 124 p. [in Russian].

12. Alekseev D.V. Priblizhenie funktsii neskol'kikh peremennykh neironnymi setyami [Approximation of Functions of Several Variables by Neural Networks]. *Fundamental'naya i prikladnaya matematika – Fundamental and Applied Mathematics*, 2009, Vol. 15, No. 3, pp. 9-21. Available at: https://elibrary.ru/download/elibrary_12996342_40485360.pdf (accessed 25.12.2018). [in Russian].

13. Funahashi K. On the Approximate Realization of Continuous Mappings by Neural Networks. *Neural Networks*, 1989, Vol. 2, No. 3, pp. 183-192.

14. Hornik K., Stinchcombe M., White H. Multilayer Feedforward Networks are Universal Approximators. *Neural Networks*, 1989, Vol. 2, No. 5, pp. 359-366.

15. White H., Gallant A.R., Hornik K., Stinchcombe M., Wooldridge J. *Artificial Neural Networks: Approximation and Learning Theory*. Cambridge, MA: Blackwell, 1992.

16. Yager R., Zadeh L. (Eds.) *Fuzzy Sets, Neural Networks and Soft Computing*. Van Nostrand Reinhold. New York, 1994.

17. H. Mohamad. *Fundamentals of Artificial Neural Networks*. Cambridge, MIT Press, 1995.

18. Winograd S., Cowan J. D. *Reliable Computation in The Presence of Noise*. Cambridge, MIT Press, 1963. 247p.

19. Rosenblatt F. The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. *Psychological Review*, 1958, No. 65, 386-408 p.

20. Widrow B. *Generalisation and Information Storage in Networks of Adaline «Neurons»*. Self-Organizing Systems. Washington, D.C.: Sparta, 1962. 435-461 p.

Авторы

• Костарева Светлана Николаевна, канд. техн. наук
Уфимский государственный нефтяной технический университет
Доцент кафедры «Промышленная теплоэнергетика»
Российская Федерация, 450062, г. Уфа, ул. Космонавтов, 1
e-mail: kostarevasn@mail.ru

The Authors

• Kostareva Svetlana N., Candidate of Engineering Sciences
Ufa State Petroleum Technological University
Assistant Professor of Industrial Heat and Power Engineering Department
1, Kosmonavtov str., Ufa, 450062,
Russian Federation
e-mail: kostarevasn@mail.ru

• Байков Игорь Равильевич, д-р техн. наук, профессор
Уфимский государственный нефтяной
технический университет
Заведующий кафедрой «Промышленная
теплоэнергетика»
Российская Федерация, 450062, г. Уфа,
ул. Космонавтов, 1
e-mail: pte@rusoil.net

• Baikov Igor R., Doctor of Engineering Sciences,
Professor
Ufa State Petroleum Technological University
Head of Industrial Heat and Power Engineering
Department
1, Kosmonavtov str., Ufa, 450062,
Russian Federation
e-mail: pte@rusoil.net

• Смородова Ольга Викторовна, канд. техн. наук
Уфимский государственный нефтяной
технический университет
Доцент кафедры «Промышленная
теплоэнергетика»
Российская Федерация, 450062, г. Уфа,
ул. Космонавтов, 1
e-mail: olga_smorodova@mail.ru

• Smorodova Olga V., Candidate of Engineering
Sciences
Ufa State Petroleum Technological University
Assistant Professor of Industrial Heat and Power
Engineering Department
1, Kosmonavtov str., Ufa, 450062,
Russian Federation
e-mail: olga_smorodova@mail.ru

• Киселева Софья Алексеевна
Уфимский государственный нефтяной
технический университет
Студент кафедры «Промышленная
теплоэнергетика»
Российская Федерация, 450062, г. Уфа,
ул. Космонавтов, 1
e-mail: sonya.kiseleva.97@mail.ru

• Kiseleva Sofia A.
Ufa State Petroleum Technological University
Student of Industrial Heat and Power
Engineering Department
1, Kosmonavtov str., Ufa, 450062,
Russian Federation
e-mail: sonya.kiseleva.97@mail.ru