

## ПРИМЕНЕНИЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ АНАЛИЗА ЭКСПЕРИМЕНТАЛЬНЫХ ДАННЫХ ГОРЕНИЯ СМЕСЕВЫХ ТВЁРДЫХ ТОПЛИВ

Аверьков И.С\*, Власов С.О.\*\* , Разносчиков В.В.\*\*\*

Центральный институт авиационного моторостроения им. П.И. Баранова,  
ЦИАМ, Авиамоторная ул., 2, Москва, 111116, Россия

\* e-mail: averkov@ciam.ru

\*\* e-mail: sergeyvlasovsaylor@yandex.ru

\*\*\* e-mail: raznoschikov@ciam.ru

Статья поступила в редакцию 02.12.2019

Экспериментальная отработка ракетно-прямоточных двигателей (РПДТ) представляет собой исследование работоспособности твердого топлива в условиях конкретной конструкции двигателя. Эксперименты такого рода требуют больших трудозатрат и являются дорогостоящими. Для снижения затрат на испытания РПДТ и ускорения разработки требуется качественная обработка полученных экспериментальных данных. В статье показана возможность использования технологии искусственных нейронных сетей (ИНС) в задачах обработки эксперимента по горению твердого топлива. Приводятся краткое описание нейронной сети типа «многослойный перцептрон» и порядок работы с ИНС при решении задач аппроксимации экспериментальных данных. На примере обработки данных горения трёхкомпонентного топлива продемонстрирован основной принцип применения нейронных сетей. Для топлива, содержащего (7Н-трис([1,2,5]оксадиазоло)[3,4-б:3',4'-д:3'',4''-f]азепин-7-амин-1-оксид)  $C_6H_2N_8O_4$ , получена зависимость скорости горения от соотношения компонентов, входящих в состав топливной смеси, и давления в камере сгорания на основе экспериментальных данных. Полученные результаты позволяют сформировать непрерывную функцию, пригодную для использования в математической модели более высокого уровня в качестве верифицированной базы данных свойств топлив.

*Ключевые слова:* аппроксимация, горение топлива, искусственная нейронная сеть, обработка экспериментальных данных, моделирование процессов.

### Введение

При исследовании и решении задач, связанных с построением математической модели РПДТ, возможны ситуации, когда модель процесса имеет сложное аналитическое описание или большое количество допущений. При этом требуется, чтобы она адекватно отражала исследуемый стохастический процесс. Для повышения точности полученных результатов в таких случаях проводится ряд экспериментальных исследований, на основе которых в модель вводятся поправки [1–3]. По этой причине при расчете РПДТ возникает задача введения в математическую модель двигателя множества экспериментальных данных: скорости горения, полноты сгорания топлива и т.д.

Нейронные сети широко применяются в различных областях — бизнесе, медицине, технике, геологии, физике, биологии и др. [4–9]. ИНС используются в случае когда необходимо решать

задачи прогнозирования, классификации или автоматизации при наличии большого количества статистических данных, для которых нет аналитических методов решения либо они весьма трудоемки в реализации. Нейронные сети — мощный метод моделирования, позволяющий воспроизводить чрезвычайно сложные нелинейные зависимости [10, 11]. Кроме того, нейронные сети справляются с «проклятием размерности», которое не позволяет моделировать линейные зависимости в случае большого числа переменных [5, 12].

Пользователь нейронной сети подбирает представительные данные (обучающую выборку), а затем запускает алгоритм обучения. От пользователя требуется набор знаний о том, как следует отбирать и подготавливать данные, выбирать нужную архитектуру сети и интерпретировать результаты [13].

Неотъемлемой частью новых исследований является хранение и обработка большого количества информации о проведенных ранее работах. В настоящей статье рассматривается процесс создания электронной базы данных экспериментальных исследований по определению скорости горения многокомпонентных смесевых твердых топлив, её последующей обработки и анализа с помощью использования искусственных нейронных сетей.

### Основные сведения по обработке экспериментальных исследований с помощью ИНС

Нейронная сеть — это набор нейронов, определенным образом связанных между собой. Работу искусственного нейрона и ИНС можно описать следующим образом [4, 14] (рис. 1).




Рис. 1. Нейрон (а) и архитектура многослойного перцептрона (б)

Нейрон получает входные сигналы через несколько входных каналов. Каждый входной сигнал проходит через соединение, имеющее определенную интенсивность (вес). Вычисляется взвешенная сумма входов, из нее вычитается пороговое значение, и в результате получается величина активации нейрона, которая преобразуется с помощью функции активации. В итоге получается выходной сигнал нейрона.

Наиболее распространенными являются сети, в которых нейроны объединены в слои.

Существуют различные методы обучения нейронных сетей [15—18]. Наиболее известный вариант алгоритма обучения нейронной сети — алгоритм обратного распространения [19].

Блок-схема обработки экспериментальных данных с использованием ИНС представлена на рис. 2.

Порядок работы с ИНС при обработке экспериментальных данных:

1) получение результатов экспериментов как исходных данных, анализ их адекватности;

2) формирование выборки на основе полученных данных — массивов значений каждого компонента, входящего в состав топлива и выходных параметров;

3) настройка нейронной сети: задание числа слоев, количества нейронов в каждом слое, требуемой точности, метода обучения, нормы обучения, начальных весов связей между нейронами и т.д.;

4) начало работы нейронной сети (обучение) — подбор программой весов входных каналов нейронов до достижения требуемой точности соответствия выходных сигналов ИНС и исходной выборки по заданному алгоритму;

5) обработка полученных результатов: определение степени обучения ИНС (отсутствие недообученности и переобученности), сравнение соответствия выходных сигналов ИНС в исходных точках с заданными значениями (требуемая погрешность может достигаться ИНС не за счет усреднения ошибки, а её минимизацией в отдельных точках, в то время как в других точках погрешность может быть большой), оценка полученных значений весовых коэффициентов входных каналов и т.д.;

б) выполнение расчетов с использованием обученной ИНС: прогнозирование значений функции в точках, не входящих в обучающую выборку, анализ топологии функции в желаемых диапазонах входных параметров (интерполяция), оценка функции за пределами изменения входных параметров (экстраполяция).

В некоторых случаях адекватность настройки ИНС можно определить только после построения топологии исследуемой функции. Для этого нужно выполнить оценку «физичности» полученных результатов. При неудовлетворительном результате необходимо проверить верность заданной обучающей выборки и перенастроить ИНС с последующим её обучением. Если и эти действия не дают необходимого результата, требуется проверить данные эксперимента.

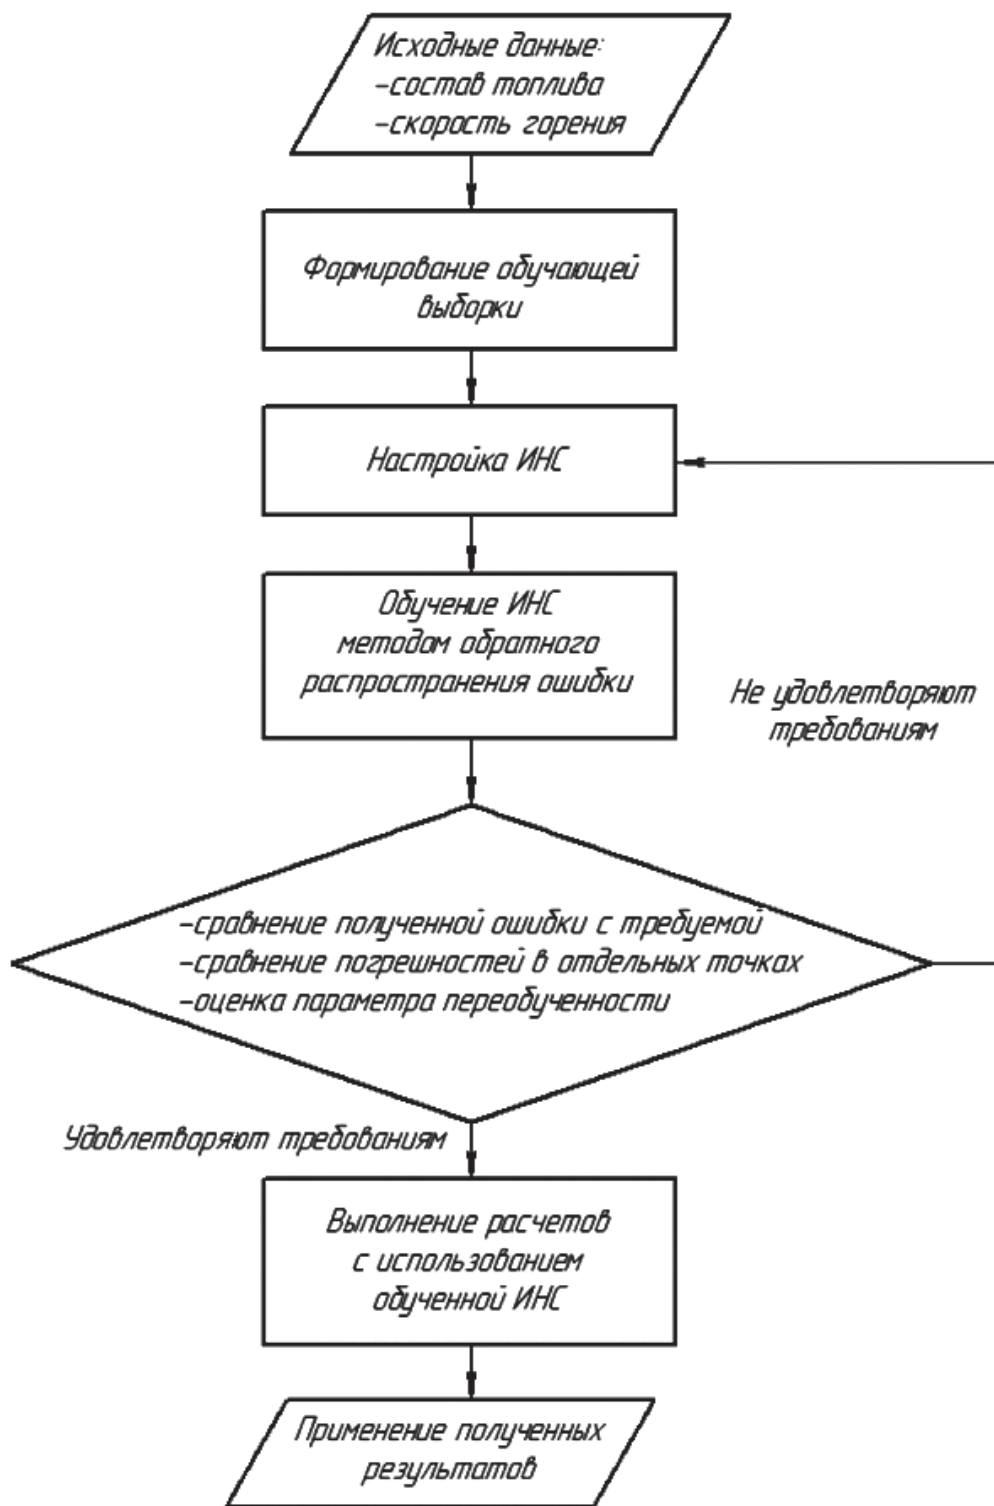


Рис. 2. Блок-схема обработки экспериментальных данных с использованием ИНС

### Постановка задачи

Для математического моделирования работы газогенератора и регулятора расхода топлива РПДТ требуется знать скорость горения твердого топлива. Массовые доли компонентов твердого топлива включены в вектор варьируемых перемен-

ных. Для каждого анализируемого состава и давления, при котором горит топливо, требуется знать скорость его горения. Но проводить эксперимент для каждого из вариантов топлива нецелесообразно по причине сложности, дороговизны и длительности выполнения. Более того, при про-

Таблица 1

Экспериментальные точки по определению скорости горения трехкомпонентного смесового твердого топлива

№	$C_6H_2N_8O_4$	ПХА	Каучук	$P$ , атм	$U$ , мм/с
1	100	0	0	20	3,1
				60	6,6
2	90	10	0	20	3,73
				60	8,1
3	80	0	20	20	2,7
				60	5,2
4	70	0	30	20	2,4
				60	4
5	70	10	20	20	3,1
				60	4,83
6	60	0	40	20	1,9
				60	3,4
7	50	0	50	20	1
				60	1,7
8	40	10	50	20	0,85
				60	2,03

ведении экспериментов имеется возможность получить значения параметров горения топлив только при конкретных составах, а значит, они дают ограниченное количество сведений для выполнения расчетов. По этой причине предлагается провести анализ конкретных составов в исследуемой области и выполнить аппроксимацию по полученным точкам. Таким образом, получается функция, отражающая поведение скорости горения в зависимости от состава твердого топлива и давления. Новая информация в конечном виде представляет собой матрицу базы данных скоростей горения в определенных интервалах варьируемых переменных.

**Пример расчёта**

Имеется трехкомпонентное смесовое топливо из (7Н-трис([1,2,5]оксадиазоло)[3,4-б:3',4'-д:3'',4''-f]азепин-7-амин-1-оксид)  $C_6H_2N_8O_4$ , перхлората аммония (ПХА)  $NH_4ClO_4$  и связующего (каучук). Прогнозируемый параметр — скорость горения при различных составах и давлениях.

Состав трехкомпонентного топлива можно представить на плоскости в виде графика, изображенного на рис. 3. На нем точками указаны составы топлив, для которых имелись экспериментальные данные о скорости горения. При постоянном количестве ПХА можно подобрать такое соотношение связующего и  $C_6H_2N_8O_4$ , что их общая сумма даст требуемые 100%.

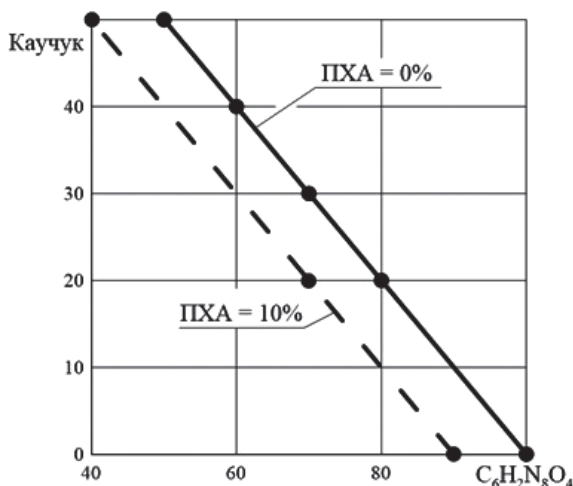


Рис. 3. Экспериментальные данные

**Анализ полученных результатов**

Рассматриваемая ИНС реализована на языке Фортран и является частью программного комплекса АХА [20]. Созданные на базе нейронных сетей модули легко интегрируются с другими ча-

стями комплекса. Для работы пользователю достаточно общих понятий о структуре работы ИНС, полученных из [21] и упомянутых в данной статье. Исследователь проводит изменение настроечных параметров ИНС в заранее созданной форме, проводит обучение ИНС и получает результат, хранящий информацию о достигнутой точности в исходных точках, значениях весовых функций ИНС и т.д. Основываясь на них, он может или сохранить полученные параметры ИНС и в дальнейшем использовать их для получения прогнозов параметров горения твердого топлива любого состава, или изменить настроечные параметры и провести переобучение ИНС.

Полученные топологии поверхности скорости горения в зависимости от состава топлива и давления представлены на рис. 4.

Топологии построены на базе экспериментальных исследований, представленных в табл. 1, и могут использоваться в дальнейшем при формировании новых обликов РПДТ.

Таблица 2

Диапазоны изменения варьируемых переменных

ПХА, %	0—10
$C_6H_2N_8O_4$ , %	50—100
Каучук, %	0—50
$P$ , атм	20—60

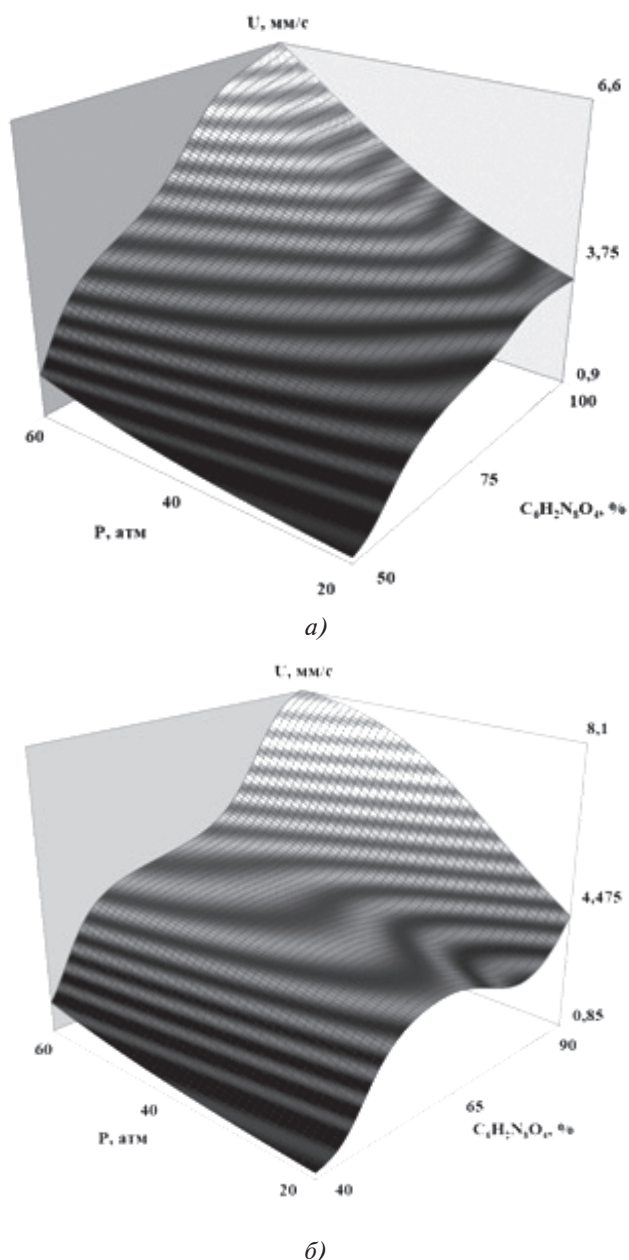


Рис. 4. Топология скорости горения смешанного твердого топлива при содержании ПХА: а — 0%; б — 10%

Необходимо учитывать, что все эксперименты имеют некоторую погрешность. Полученные с использованием ИНС поверхности позволяют выявить точки, в которых случайные погрешности могли достичь высоких значений, что становится заметным по поведению функции. Если значение функции в точке нарушает характер поведения исследуемой величины — возможно, следует провести в данной области дополнительный эксперимент.

ИНС позволяет сформировать топологию функции (скорости горения) в диапазоне, представленном в табл. 2.

Выводы

1. Обработка экспериментальных данных с помощью ИНС позволяет сформировать матрицу базы данных скоростей горения в определенных интервалах варьируемых переменных.

2. Анализ топологии скорости горения дает основания анализировать физичность результатов, полученных при экспериментах, а следовательно, и определять эксперименты, в которых могли быть допущены ошибки.

3. Используемая в настоящем исследовании методика является составной частью программного комплекса АХА и предназначена для оперативной связи эксперимента с расчетом [20].

*Авторы статьи благодарят за предоставленные экспериментальные данные по скоростям горения твердых топлив (табл. 1) М.Б. Кислову и А.Ф. Жолудеву, ИПХФ РАН г. Черноголовка.*

Библиографический список

1. Крылов Б.А., Онищик И.И., Юн А.А. Моделирование процессов тепло- и массообмена в модельных камерах сгорания // Вестник Московского авиационного института. 2009. Т. 16. № 1. С. 27-30.
2. Богданов В.И. Исследования по реализации пульсирующих рабочих процессов в реактивных двигателях // Вестник Московского авиационного института. 2017. Т. 24. № 4. С. 100-109.
3. Рябов А.А., Романов В.И., Куканов С.С., Шмотин Ю.Н., Габов Д.В. Расчетно-экспериментальный критерий динамической прочности корпуса газотурбинного двигателя при обрыве лопатки ротора // Вестник Московского авиационного института. 2015. Т. 22. № 3. С. 76-84.
4. Дорофеев Е.А., Дынников А.И., Каргопольцев А.В., Свириденко Ю.Н., Фадеев А.С. Применение искусственных нейронных сетей для обработки и анализа данных аэродинамического эксперимента // Ученые записки ЦАГИ. 2007. Т. XXXVIII. № 3-4. С. 111-118.
5. Филатова Т.В. Применение нейронных сетей для аппроксимации данных // Вестник Томского государственного университета. 2004. № 284. С. 121-125.

6. Рейзлин В.И. Численные методы оптимизации: Учебное пособие. — Томск: Изд-во Томского политехнического университета, 2011. — 105 с.
7. Матющенко Н.С., Копырин А.С. Применение искусственных нейронных сетей для моделирования спроса на досуговые и развлекательные услуги // Известия Сочинского государственного университета. 2012. № 3(21). С. 51–62.
8. Аравин О.И. Применение искусственных нейронных сетей для анализа патологий в кровеносных сосудах // Российский журнал биомеханики. 2011. Т. 15. № 3(53). С. 45–51.
9. Абашев О.В., Куприков М.Ю. Применение искусственных нейронных сетей при проектировании самолетов // Вестник Московского авиационного института. 2008. Т. 15. № 5. С. 27–33.
10. Игнатьев Д.И. Применение искусственных нейронных сетей для моделирования аэродинамических характеристик треугольного крыла // Вестник Московского авиационного института. 2010. Т. 17. № 6. С. 5–12.
11. Брусов В.С., Тюменцев Ю.В. Синтез оптимального ансамбля нейроконтроллеров для многорежимного летательного аппарата // Вестник Московского авиационного института. 2006. Т. 13. № 2. С. 67–78.
12. Блинов А.О., Фраленко В.П. Многомерная аппроксимация в задачах моделирования и оптимизации // Автоматика и телемеханика. 2009. № 4. С. 98–109.
13. Коробкова С.В. Проблемы эффективной аппроксимации многомерных функций с помощью нейронных сетей // Известия ТРТУ. 2006. № 3(58). С. 121–127.
14. Боровиков В.П. Нейронные сети Statistica Neural Networks: Методология и технологии современного анализа данных: Учебное пособие. — 2-е изд., перераб. и доп. — М.: Телеком, 2008. — 392 с.
15. Рудой Г.И. Выбор функции активации при прогнозировании нейронными сетями // Машинное обучение и анализ данных. 2011. Т. 1. № 1. С. 16–39.
16. Bishop C.M. Neural Networks for Pattern Recognition. — Oxford University Press, USA, 1995. — 502 p.
17. Гулаков К.В. Выбор архитектуры нейронной сети для решения задач аппроксимации и регрессионного анализа экспериментальных данных // Вестник Брянского государственного технического университета. 2013. № 2(38). С. 95–105.
18. Беляев М.Г., Приходько П.В., Бурнаев Е.В., Берштейн А.В. Аппроксимация многомерной зависимости с помощью градиентного усиления регрессионной нейронной сети и ее применение в быстром методе аэродинамического расчета для задач проектирования // Математическое моделирование и программное обеспечение: Сборник трудов конференции молодых учёных (Санкт-Петербург, 14–17 апреля 2009). — М: Изд-во ИТМО, 2009. Вып. 4. С. 46–51.
19. Калацкая Л.В., Новиков В.А., Садков В.С. Организация и обучение искусственных нейронных сетей: Учебное пособие. — Минск: БГУ, 2002. — 76 с.
20. Сорокин В.А. (ред.). Проектирование и отработка ракетно—прямоточных двигателей на твердом топливе: Учебное пособие. — М.: Изд-во МГТУ им. Н.Э. Баумана, 2016. С. 9–63.
21. Хайкин С.О. Нейронные сети: полный курс. — 2-е изд. / Пер. с англ. и ред. Н.Н. Куссуль. — М.: ИД «Вильямс», 2016. — 1104 с.

## ARTIFICIAL NEURAL NETWORKS APPLICATION FOR EXPERIMENTAL DATA ANALYSIS OF COMPOSITE SOLID PROPELLANTS COMBUSTION

Aver'kov I.S\*, Vlasov S.O.\*\* , Raznoschikov V.V.\*\*\*

Central Institute of Aviation Motors named after P.I. Baranov,  
CIAM, 2, Aviamotornaya str., Moscow 111116, Russian Federation

\* e-mail: averkov@ciam.ru

\*\* e-mail: sergeyvlasovsaylor@yandex.ru

\*\*\* e-mail: raznoschikov@ciam.ru

### Abstract

While studying and solving the problems associated with a ramjet mathematical model developing, situations occur when a process model contains a complex mathematical formulation or a large number of assumptions. A number of experimental studies is being conducted in such cases, based on which corrections are being introduced to the model to increase accuracy of the obtained results.

The presented article regards the process of creating an electronic database of experimental studies on determination of the multicomponent combined solid propellant combustion rate, with their subsequent processing and analyzing with artificial neural networks.

For gas generator and propellant consumption regulator of a ramjet operation modelling, information on combustion rate of a solid propellant is required.

Mass fractions of solid propellant components are included in the alterable variables vector. It is unreasonable to conduct experiments for all analyzed propellant compositions due to the complexity, expensiveness and long duration of their implementation. The authors suggest conducting experimental studies of particular compositions in the area under study and performing approximation by the obtained points. As the result, a function, reflecting the combustion rate behavior in dependence of the solid propellant composition and pressure is obtained.

There is a three-component propellant being a mixture of  $C_6H_2N_8O_4$ , ammonium perchlorate  $NH_4ClO_4$  and a binder (rubber). The predicted parameter is the burning rate at various compositions and pressures.

The obtained topologies are built based on experimental research, and can be used later in formation of appearances of new ramjet engines.

When processing the obtained results, it is necessary to account for the fact that all experiments have certain error. The surfaces, obtained by neural networks allow identify the points at which random errors could reach high values, which is become noticeable by the function behavior.

1. Experimental data processing using neural networks allows forming a matrix of combustion rates database in specified intervals of alterable variables.

2. The burning rate topology analysis give grounds for analyzing the results obtained during the experiments, and, thus, to determine the experiments in which errors could be made.

**Keywords:** approximation, fuel combustion, artificial neural network, experimental data processing, processes modeling.

## Reference

1. Krylov B.A., Onishchik I.I., Yun A.A. A simulation of mass and heat exchange within model combustion chambers. *Aerospace MAI Journal*, 2009, vol. 16, no. 1, pp. 27-30.
2. Bogdanov V.I. Research on realization of pulsating working processes in jet engines. *Aerospace MAI Journal*, 2017, vol. 24, no. 4, pp. 100-109.
3. Ryabov A.A., Romanov V.I., Kukanov S.S., Shmotin Yu.N., Gabov D.V. Numerical and experimental criterion of gas turbine engine hull dynamic strength in case of open rotor blade out. *Aerospace MAI Journal*, 2015, vol. 22, no. 3, pp. 76-84.

4. Dorofeev E.A., Dynnikov A.I., Kargopol'tsev A.V., Sviridenko Yu.N., Fadeev A.S. *Uchenye zapiski TsAGI*, 2007, vol. XXXVIII, no. 3-4, pp. 111-118.
5. Filatova T.V. *Vestnik Tomskogo gosudarstvennogo universiteta*, 2004, no. 284, pp. 121-125.
6. Reizlin V.I. *Chislennyye metody optimizatsii* (Numerical optimization methods), Tomsk, Tomskii politekhnicheskii universitet, 2011, 105 p.
7. Matyushchenko N.S., Kopyrin A.S. *Izvestiya Sochinskogo gosudarstvennogo universiteta*, 2012, no. 3(21), pp. 51-62.
8. Aravin O.I. *Rossiiskii zhurnal biomekhaniki*, 2011, vol. 15, no. 3(53), pp. 45-51.
9. Abashev O.V., Kuprikov M.Yu. An application of artificial neural networks in aircraft design. *Aerospace MAI Journal*, 2008, vol. 15, no. 5, pp. 27-33.
10. Ignatyev D.I. Application of artificial neural networks for simulation of delta wing aerodynamic characteristics. *Aerospace MAI Journal*, 2010, vol. 17, no. 6, pp. 5-12.
11. Brusov V.S., Tiumentsev Yu.V. A synthesis of optimal neurocontroller ensemble for multiple-regime aircraft. *Aerospace MAI Journal*, 2006, vol. 13, no. 2, pp. 67-78.
12. Blinov A.O., Fralenko V.P. Multidimensional approximation for modeling and optimization problems. *Automation and Remote Control*, 2009, vol. 70, no. 4, pp. 652-662. DOI: 10.1134/S0005117909040110
13. Korobkova S.V. *Izvestiya TRTU*, 2006, no. 3(58), pp. 121-127.
14. Borovikov V.P. *Neironnye seti Statistica Neural Networks. Metodologiya i tekhnologii sovremennoy analiza dannykh* (Neural networks. STATISTICA Neural Networks. Methodology and technologies of modern data analysis), Moscow, Telekom, 2008, 392 p.
15. Rudoi G.I. *Mashinnoe obuchenie i analiz dannykh*, 2011, vol. 1, no. 1, pp. 16-39.
16. Bishop C.M. *Neural Networks for Pattern Recognition*. Oxford University Press, USA, 1995, 502 p.
17. Gulakov K.V. *Vestnik Bryanskogo gosudarstvennogo tekhnicheskogo universiteta*, 2013, no. 2(38), pp. 95-105.
18. Belyaev M.G., Prikhod'ko P.V., Burnaev E.V., Bernshtein A.V. *Materialy konferentsii molodykh uchenykh (Saint-Petersburg, 14-17 April 2009) "Matematicheskoe modelirovanie i programnoye obespechenie"*, Moscow, ITMO, 2009, no. 4, pp. 46-51.
19. Kalatskaya L.V., Novikov V.A., Sadkov V.S. *Organizatsiya i obuchenie iskusstvennykh neironnykh setei* (Organization and training of artificial neural networks), Minsk, BGU, 2002, 76 p.
20. Sorokin V.A. (red.) *Proektirovanie i otrabotka raketno-pryamotochnykh dvigatelei na tverdom toplive* (Design and development of rocket-ramjet engines on solid fuel), Moscow, MGTU im. N.E. Baubana, 2016, pp. 9-63.
21. Haykin S.O. *Neural Networks: A Comprehensive Foundation*. Second Edition. Prentice Hall, New Jersey, 1999, 842 p.