

## **Использование нейронных сетей для построения прогностических моделей процессов в энергетических установках и их агрегатах**

*С.Г. Зароченцев<sup>1,2</sup>, В.И. Ковалев<sup>2</sup>, А.А. Пастухов<sup>1,2</sup>, А.А. Прокофьев<sup>1</sup>*

<sup>1</sup>*Национальный исследовательский университет «МИЭТ»*

<sup>2</sup>*Акционерное общество «НПО Энергомаш имени академика  
В.П. Глушко» (г. Химки)*

## **Simulation Modeling Using Neural Network to Create Prediction Models of Processes in Liquid-Propellant Rockets and Their Aggregates**

*S.G. Zarochentsev<sup>1,2</sup>, V.I. Kovalev<sup>2</sup>, A.A. Pastukhov<sup>1,2</sup>, A.A. Prokofiev<sup>1</sup>*

<sup>1</sup>*National Research University of Electronic Technology, Moscow*

<sup>2</sup>*«NPO Energomash named after V.P. Glushko», JSC, Khimki*

Представлен опыт внедрения информационно-измерительных технологий и имитационного моделирования в практику стендовой отработки различных изделий ракетно-космической техники. Рассмотрен пример использования нейросетевого имитационного моделирования применительно к задаче построения прогностической модели прироста давления в насосе горючего турбонасосного агрегата жидкостного ракетного двигателя в зависимости от скорости потока и концентрации полимерной присадки. Приведены этапы программной реализации соответствующей нейросетевой модели, а также описание пользовательского интерфейса. С помощью модели уточнена оптимальная концентрация полимерной присадки, позволяющая увеличить КПД насоса горючего жидкостного ракетного двигателя.

*Ключевые слова:* стендовая система функциональной диагностики жидкостного ракетного двигателя; нейросетевая имитационная модель.

An experience of introducing the measuring and information technologies and simulation modeling into the bench tests of various space industry products has been presented. An example of using the neural network simulation modeling potential to predict the pressure in a turbo pump depending on the flow rate and the polymer additive concentration has been considered. The stages of the neural network model implementation as well as the user interface description have been presented. Using the model the optimal concentration of the polymer additive, permitting to increase the efficiency of the liquid-propellant fuel pump, has been refined.

*Keywords:* test bench system of functional diagnostics of liquid-propellant rockets; neural networks simulation model.

**Введение.** В настоящее время практически все новые разработки как за рубежом, так и в России ведутся с использованием имитационного моделирования. В АО «НПО Энергомаш» начиная с 1990-х гг. был создан ряд имитационных моделей, позволивших в сжатые сроки внедрить стендовую систему функциональной диагностики основных параметров жидкостного ракетного двигателя (ЖРД) [1]. В частности, для внедрения информационно-измерительной системы для визуального контроля стендовых параметров на базе современной измерительной аппаратуры в открытом стандарте VXI (VMEbus eXtention for Instrumentation) создана имитационная модель, позволившая внедрить данную систему собственными силами и с минимальными затратами.

Кроме того, в стендовую систему функциональной диагностики входят еще пять штатных систем, три из которых уже внедрены:

- система управления режимами, работающая только на режиме пуска, 12 параметров, VME стандарт, среда разработки SCADA-системы;
- система телеконтроля, состоящая из 48 специальных видеокамер;
- система контроля и диагностики, базирующаяся на специальных видеокамерах, установленных внутри бронекамеры.

Еще две системы – информационно-измерительная и система контроля технологии – находятся на стадии внедрения на базе аппаратуры в VXI стандарте.

Необходимо отметить, что система телеконтроля позволяет вести непрерывный мониторинг технологии проведения огневых испытаний на всех его режимах. С использованием системы телеконтроля отработан датчик магнитного поля, определены оптимальные точки фокусировки лазера, а также необходимая частота лазерного импульса при стендовой отработке лазерного зажигательного устройства.

В последние десятилетия наблюдается активный рост мощности современных ПЭВМ, поэтому представляется возможным применение более совершенных ресурсоемких алгоритмов для построения компьютерных моделей. В настоящее время проводятся исследования в области разработки технологии нейросетевого имитационного моделирования (НИМ) применительно к задаче оптимизации стендовой отработки различных систем и новых изделий ракетно-космической техники. Преимущество нейросетевой имитационной модели состоит в том, что она может оптимально настраиваться (обучаться) на требуемый отклик, учитывая как контролируемые, так и неконтролируемые параметры, а именно: теоретические модели в тех областях параметров, где они применимы, результаты ранее проведенных натуральных экспериментов, результаты численных расчетов по математическим моделям, текущие результаты проводимой в данный момент серии экспериментов.

В настоящей работе на базе технологии НИМ описывается разработка и реализация прогностической имитационной модели давления в насосе горючего турбонасосного агрегата (ТНА) при различных значениях объемных расходов и концентрациях полимерной присадки.

Характеристики ЖРД во многом определяются совершенством топливной системы [2]. Гидравлический тракт системы подачи современных ЖРД состоит из элементов, которые повышают полное давление рабочего тела (насосные агрегаты), и элементов, в которых оно безвозвратно теряется в виде гидравлических потерь (клапаны, регуляторы) и сопротивления трения (топливные магистрали, тракты охлаждения). Соответственно, существуют два способа улучшения характеристик топливной системы: 1) увеличение КПД лопастных насосов; 2) снижение гидравлических потерь в элементах топливной системы.

Первый способ при сохранении остальных параметров на прежнем уровне чрезвычайно сложен. Причем его сложность пропорциональна достигнутому КПД. Потери трения (второй способ) зависят от числа Рейнольдса и шероховатости стенок, для устранения которых на предприятиях отрасли резервов не имеется. В такой ситуации может применяться эффект Томса, который заключается в снижении гидродинамического сопротивления трения в потоке около стенки в результате добавления в топливо высокомолекулярных полимеров.

Следует отметить, что сложность процессов, проходящих в турбонасосном агрегате ЖРД, создает определенные трудности для построения их математических моделей. Для определения оптимальной массовой концентрации полимерной добавки необходимо проведение большого количества огневых испытаний. В представленном исследовании на основе данных, полученных в огневых испытаниях четырех образцов ЖРД, в АО «НПО Энергомаш» построена прогностическая модель давления  $H$ , м вод. ст., в насосе горючего ТНА при различных скоростях потока горючего  $V$ , л/с, и массовой концентрации присадки  $C$ , %. В математической интерпретации данная задача сводится к нахождению функциональной зависимости  $H: H = f(V, C)$ .

Применяя полученную модель, можно определить оптимальную концентрацию полимерной присадки к горючему с целью получения на выходе максимального прироста давления.

**Этап подготовки исходных данных.** Показания скорости потока с соответствующими показаниями давления в ТНА измерялись как с использованием топлива без присадок, так и с примесью полиизобутилена различной концентрации (0,005; 0,05; 0,08 и 0,095 %). Всего проведено 50 экспериментальных реализаций для пяти значений концентраций [2]. По результатам огневых испытаний строится факторное пространство, состоящее из двух групп.

Первая группа – входные параметры. Введем следующие обозначения:  $X = \{x_1, x_2\}$ , где  $x_1 \in [0; 0,095]$  – концентрация присадки по массе, %;  $x_2 \in [643; 922]$  – скорость потока в ТНА, л/с.

Вторая группа – выходные параметры. Обозначим  $Y = \{y\}$ , где  $y \in [5625; 6250]$  – давление в ТНА, м вод. ст.

Таким образом, факторное пространство есть множество  $V = X \cup Y$ .

**Этап подготовки факторного пространства.** Прежде чем использовать факторное пространство в качестве данных для построения нейронной сети, необходимо провести его предварительную подготовку,

Данные, используемые при обучении нейронной сети, нормируются в соответствии с областью значений функции активации, в качестве которой используется сигмоидальная функция. В рассматриваемом случае входные параметры принимают как положительные, так и отрицательные значения, поэтому в качестве функции активации

$f(x)$  взят гиперболический тангенс  $f(x) = \text{th}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$ . Эта функция непрерывно

дифференцируема на всей числовой оси  $f'(x) = 1 - \text{th}^2(x)$  и позволяет решать проблему шумового насыщения, что является необходимым для корректного функционирования алгоритмов обучения.

Начальная инициализация сети проводилась методом Нгуен – Видроу [3].

**Этап построения модели нейронной сети.** В работе [4] проведен анализ нейронных сетей нескольких типов применительно к решению различных задач. Для решения

задачи прогнозирования можно использовать два типа сетей: многослойный перцептрон (MLP – multilayer perceptron) и сеть радиально-базисных функций (RBF – radial basis function). При относительно малой размерности обучающей выборки, что имеет место в данном исследовании, следует применять сети типа MLP.

Оценка количества связей сети определяется по формуле, которая следует из теоремы Арнольда – Колмогорова – Хехт-Нильсена [5]:

$$\frac{mN}{1 + \log_2 N} \leq L_w \leq m \left( \frac{N}{m} + 1 \right) (n + m + 1) + m,$$

где  $n$ ,  $m$  – размерности входного и выходного сигнала соответственно;  $N$  – число элементов обучающей выборки;  $L_w$  – общее число связей нейронной сети.

Принимая во внимание данное выражение, число нейронов в скрытом слое определим по формуле [6]

$$L = \frac{L_w}{n + m}, \quad 5 \leq L_w \leq 205.$$

Таким образом, число связей сети  $L_w$  определяется в диапазоне  $5 \leq L_w \leq 205$ , число  $L$  скрытых нейронов сети – в диапазоне  $2 \leq L \leq 68$  (округлены до целого значения).

В работе [7] отмечается, что для хорошего обобщения достаточно, чтобы размер обучающего множества удовлетворял соотношению

$$N = O(W / \varepsilon),$$

где  $W$  – общее количество свободных параметров;  $\varepsilon$  – допустимая точность ошибки классификации;  $N$  – размер обучающего множества;  $O(\bullet)$  – порядок заключенной в скобки величины.

Факторное пространство содержит 50 экспериментальных реализаций, поэтому для гарантированного достижения хотя бы значения  $\varepsilon \approx 0,10$  при двух входных параметрах количество нейронов скрытого слоя должно быть не более двух [8].

**Этап обучения нейронной сети.** В математической интерпретации задача обучения нейронной сети сводится к нахождению функциональной зависимости

$$F : F(X_i) \rightarrow y_i, \quad i = 1, 2, \dots, 50,$$

где  $X_i$  –  $i$ -я строка матрицы входных параметров  $X$ ;  $y_i$  –  $i$ -я строка матрицы выходных параметров  $Y$  (в данном случае  $i$ -й элемент вектор-столбца).

Задача решается минимизацией целевой функции ошибки нейронной сети, вычисляемой методом наименьших квадратов:

$$E(\{\omega_{ij}\}) = \frac{1}{2} \sum_{k=1}^n (r_k - y_k)^2,$$

где  $r_k$  – значение  $k$ -го выхода нейронной сети;  $y_k$  – целевое значение  $k$ -го выхода нейронной сети;  $n$  – число нейронов в выходном слое;  $\omega_{ij}$  – вес связи, соединяющий нейрон  $i$  с нейроном  $j$ .

Обучение проводилось с использованием алгоритма обратного распространения ошибки [8], который представляет собой модификацию метода эффективного вычисления градиента минимизируемой функции.

В соответствии с алгоритмом процедура обучения завершается либо по достижении ошибки заданного значения [8], либо по окончании 50 эпох обучения. Не существует точного алгоритма выбора количества эпох обучения, поэтому значение подбирается экспериментальным путем. В данном случае оказалось достаточно 50 эпох, чтобы достигнуть приемлемой ошибки обучения (ошибка составила менее 1 м вод. ст.) [2].

Отклонение спрогнозированных нейронной сетью значений от значений, полученных в результате испытаний, составило порядка 1 %, что является приемлемым результатом.

**Описание программной среды прогнозирования давления в ТНА.** Модель реализована в виде программного модуля в среде разработки NI Lab Windows CVI на языке программирования С. Схема данных программного модуля представлена на рис.1.

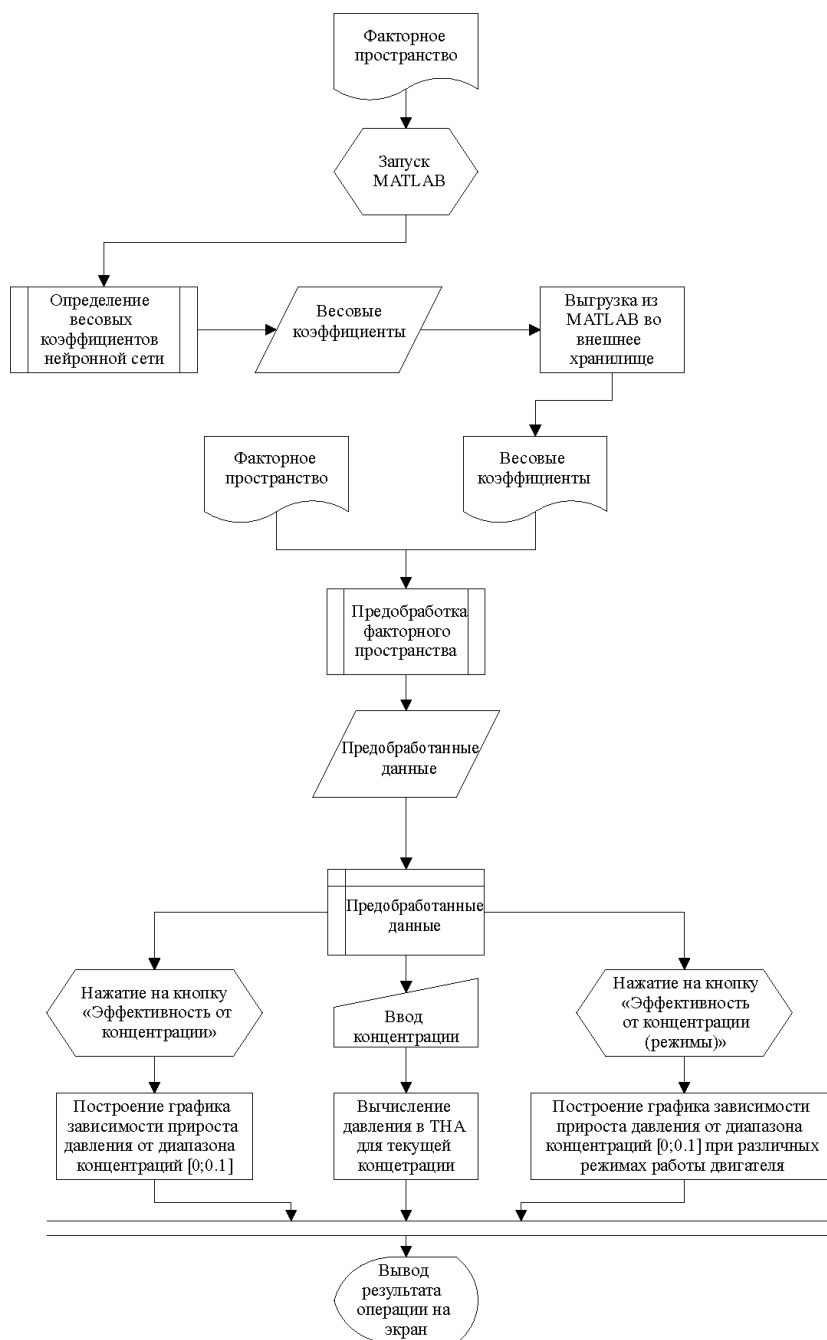


Рис.1. Схема данных программного модуля

На подготовительном этапе происходит инициализация начальных значений и загрузка пользовательского интерфейса, вид которого с возможными вариантами выбора действия представлен на рис.2.

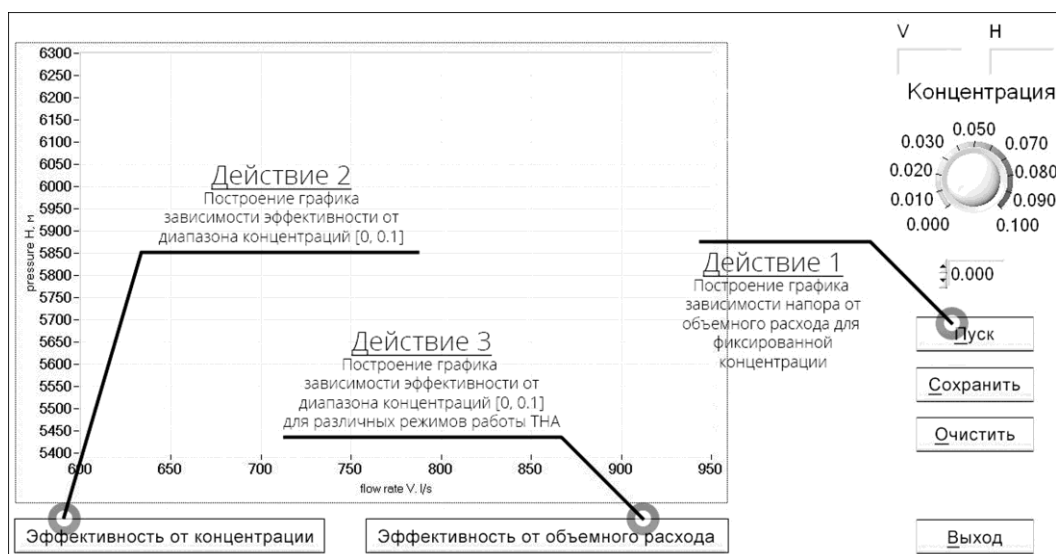


Рис.2. Вид пользовательского интерфейса программного модуля

Таким образом, программный модуль реализует модель и позволяет получить непрерывную картину зависимости скорости потока от давления при любых концентрациях присадки из диапазона [0; 0,1] %.

**Построение прогноза давления в насосе горючего с применением программного модуля.** Эффективность, или прирост напора в насосе горючего, рассчитана по следующей формуле:

$$A = \frac{\sum_{i=0}^N \frac{|H_{C_i} - H_{0_i}|}{H_{0_i}} \cdot 100\%}{N},$$

где  $A$  – эффективность, %;  $H_{0_i}$  – значение давления в  $i$ -й точке для горючего без присадки, м вод. ст.;  $H_{C_i}$  – значение давления в  $i$ -й точке для горючего с концентрацией




Рис.3. Зависимость эффективности от концентрации и режима по расходу

присадки  $C$ , м вод. ст.;  $N = 279$  – число точек для значений скорости потока от 643 до 922 л/с с шагом 1.

Эффективность рассчитывалась для значений скорости потока, составляющих 1,04; 0,96; 0,88; 0,80 от номинальной, равной 860 л/с (различные режимы работы двигателя) (рис.3).

Анализ полученных результатов (см. рис.3) позволяет сделать вывод, что наибольший прирост давления достигается при концентрации присадки в диапазоне 0,01–0,015 % на всех режимах работы.

**Заключение.** На основе разработанной прогностической имитационной модели изменения давления горючего в ТНА ЖРД в зависимости от концентрации полимерной присадки и скорости потока получено минимальное значение концентрации полимерной присадки, при которой достигается максимальный прирост давления в ТНА. Это позволяет повысить КПД ТНА, а следовательно, и удельный импульс ЖРД. Полученное значение оказалось в три раза меньше экспериментального значения без использования технологии нейросетевого имитационного моделирования [2].

### *Литература*

1. **Квак В.И., Ковалев В.И., Худяков В.Н.** Стендовая система функциональной диагностики ракетных двигателей на основе информационно-измерительных технологий и имитационного моделирования // Мир измерений. – 2013. – №9. – С. 32–36.
2. **Гапонов В.Д., Каналин Ю.И.** Возможность использования присадок высокомолекулярных полимеров для улучшения характеристик энергетических установок // ГОНТИ-17. Сер. 4. – 1989. – №69. – С. 9–18.
3. **Le Cun Y.** Efficient learning and second-order methods. – MA: MIT Press, 1993. – 71 p.
4. **Родионов П.Е.** Методика извлечения знаний в задачах анализа рядов динамики с использованием нейронных сетей: дис. ... канд. техн. наук. – М., 2003. – 169 с.
5. **Hecht-Nielsen R.** Counterpropagation networks // Proc. of the IEEE First International Conf. on Neural Networks / Eds M. Caudill and C. Butler. – San Diego, CA: SOS Printing, 1987. – Vol. 2. – P. 19–32.
6. **Девярых Д.В., Гергет О.М., Михаленко И.В.** Применение искусственных нейронных сетей для прогнозирования развития перинатального поражения нервной системы // Изв. ВолгГТУ. – 2013. – Вып. 16. – № 8 (111). – С. 77–80.
7. **Хайкин С.** Нейронные сети: полный курс. – 2-е изд.: пер. с англ. – М.: ИД «Вильямс», 2008. – 1104 с.
8. **Терехов С.А.** Лекции по теории и приложениям искусственных нейронных сетей. – Снежинск, 1998. – URL: [http://alife.narod.ru/lectures/neural/Neu\\_index.htm](http://alife.narod.ru/lectures/neural/Neu_index.htm) (дата обращения: 21.01.2016).

Статья поступила  
26 января 2016 г.

**Зароченцев Сергей Геннадьевич** – магистрант кафедры информатики и программного обеспечения вычислительных систем МИЭТ, инженер-программист АО «НПО Энергомаш» (г. Химки). *Область научных интересов:* разработка программного обеспечения, языка программирования, машинное обучение.  
**E-mail:** [sergei.zarochentsev@gmail.com](mailto:sergei.zarochentsev@gmail.com)

**Ковалев Владимир Иванович** – кандидат технических наук, начальник отдела системной интеграции и информатизации испытаний АО «НПО Энергомаш» (г. Химки). *Область научных интересов:* компьютерное моделирование, включая математическое, имитационное и нейросетевое.

**Пастухов Алексей Андреевич** – аспирант кафедры высшей математики № 1 МИЭТ, инженер-программист АО «НПО Энергомаш» (г. Химки). *Область научных интересов:* искусственные нейронные сети, разработка программного обеспечения, Data Science.

**Прокофьев Александр Александрович** – кандидат физико-математических наук, доктор педагогических наук, заведующий кафедрой высшей математики № 1 МИЭТ. *Область научных интересов:* цифровая обработка сигналов и изображений, математическое моделирование.