

УДК 622.691.4.052.012

**ОПРЕДЕЛЕНИЕ ПОКАЗАТЕЛЕЙ ЭНЕРГОЭФФЕКТИВНОСТИ  
ГАЗОПЕРЕКАЧИВАЮЩИХ АГРЕГАТОВ  
С ПРИМЕНЕНИЕМ НЕЙРОННЫХ СЕТЕЙ**

**DEFINITION OF ENERGY EFFICIENCY INDICATORS OF GAS  
TRANSFER UNITS WITH APPLICATION  
OF NEURAL NETWORKS**

**Байков И.Р., Китаев С.В., Фарухшина Р.Р.**

**ФГБОУ ВПО «Уфимский государственный нефтяной технический  
университет», г. Уфа, Российская Федерация**

**I.R. Baikov, S.V. Kitaev, R.R. Faruhshina**

**FSBEI NPE “Ufa State Petroleum Technical University”,  
Ufa, the Russian Federation**

**Аннотация.** При эксплуатации газоперекачивающих агрегатов с газотурбинным приводом существенная доля природного газа, около 9%, расходуется на собственные нужды компрессорных станций.

Значительный расход перекачиваемого газа на собственные нужды газоперекачивающих агрегатов на компрессорных станциях определяет актуальность реализации ресурсосберегающих технологий. При реализации энергосберегающих мероприятий требуется производить контроль получаемого эффекта.

Контроль потребления энергоресурсов осуществляется на основе показателей энергетической эффективности газоперекачивающих агрегатов, в состав которых входят – коэффициент полезного действия и удельный расход топливного газа.

Целью работы является разработка универсального способа расчета показателей энергоэффективности с применением интеллектуальных мето-

дов, исключающих риски снижения точности полученных результатов.

В работе предложен и обоснован способ расчета показателей энергетической эффективности по контролируемым параметрам работы газоперекачивающих агрегатов с применением нейронных сетей.

Проведенные исследования позволили получить и практически обосновать способ определения удельного расхода топливного газа по параметрам ГПА, контролируемым штатной системой автоматики, основанный на применении нейронных сетей.

Нейросетевая модель может быть интегрирована в стационарные системы мониторинга компрессорной станции нужно лишь заранее подобрать весовые коэффициенты (обучить нейронную сеть) для определенного типа ГПА.

При обучении нейронной сети, по данным с вариацией параметров в обучающей выборке 20% погрешность обучения не превышает 1%. При использовании нейронной сети для расчета показателей энергоэффективности агрегата для которого производилось обучение и для других агрегатов того же типа, средняя квадратическая погрешность не превышает 5%.

**Abstract.** When operating gas transfer units with gas turbine drive a significant share (about 9%) of natural gas is spent on compressor stations own needs.

A considerable expense of pumped gas for gas transfer units own needs at compressor stations determines the actuality of realization of resources saving technologies. When performing energy saving measures it is required to control the resulting effect.

Control of energy consumption is based on energy efficiency indicators of gas transfer units which include efficiency and gas fuel rate.

The aim of this paper was to develop a universal method of calculating energy efficiency indicators using intelligent methods which exclude risks of reducing accuracy of results.

In this paper we proposed and justified method of calculating energy efficiency indicators on the base of monitored parameters of gas transfer units work with application of neural networks.

The research made it possible to receive and to substantiate the method of determining the specific consumption of fuel gas by the parameters of HPA controlled standard automation system based on the application of intelligent neural networks.

Neural network model can be integrated in the station monitoring system compressor station need only advance to pick up army of weights to train a neural network) for a particular type HPA.

When training a neural network according to the variation of the parameters in the training set and 20% teaching error does not exceed 1%. When using neural networks for the calculation of energy efficiency indicators for the unit for which there was training for other units of the same type, the mean square error does not exceed 5%.

**Ключевые слова:** газоперекачивающий агрегат, показатели энергетической эффективности, коэффициент полезного действия, удельный расход топливного газа.

**Key words:** gas transfer unit, energy efficiency indicators, efficiency, gas fuel rate.

Газоперекачивающие агрегаты (ГПА) с газотурбинным приводом являются основным оборудованием, обеспечивающим транспортировку газа по магистральным газопроводам. Значительный расход перекачиваемого газа на собственные нужды ГПА на компрессорных станциях определяет актуальность реализации ресурсосберегающих технологий.

При этом требуется оценка уровня эффективности работы оборудования до и после реализации мероприятий, направленных на экономию энергоресурсов. В соответствии с СТО Газпром [1] в состав показателей энер-

гоэффективности входят – коэффициент полезного действия ГПА и удельный расход топливного газа.

При определении показателей энергоэффективности по параметрам газа в центробежном нагнетателе необходим расход газа, при этом не все КС оснащены замерными узлами, если принимать расчетное значение расхода, вводится существенная погрешность в расчеты.

Целью работы являлось разработка экспресс-метода расчета показателей энергоэффективности по параметрам работы ГПА с применением интеллектуальных технологий, исключающих риски снижения точности полученных результатов.

В ряде работ [2, 3] для определения диагностических признаков по технологическим показателям эксплуатации оборудования предлагаются упрощенные способы расчета, основанные на линеаризованных моделях, требующих полного набора достоверных входных параметров использующихся в расчетных моделях.

В настоящее время для решения различных задач широко применяются «интеллектуальные» алгоритмы, основанные на нейронных сетях.

Нейронным сетям и прогнозированию на их основе посвящено много работ [4, 5, 6, 7]. Нейронные сети (НС) – математические модели, а также программные или аппаратные реализации, построенные по принципу организации и функционирования биологических нейронных сетей – сетей нервных клеток живого организма. Нейронные сети не программируются, а обучаются по исходному набору данных. Возможность обучения – одно из главных преимуществ нейронных сетей перед традиционными алгоритмами.

Технически обучение заключается в нахождении коэффициентов связей между нейронами. НС применяются для решения задач классификации и распознавания образов, оптимизации, прогнозирования и автоматизации. Рассмотрим алгоритм обучения, основанный на обратном распространении ошибки [4], который позволяет получить наиболее точные результаты.

Суть алгоритма заключается в следующем. Основу алгоритма составляет целевая функция, определенная для всех  $p$  пар обучающих выборок  $(x_j, d_j)$ , в виде:

$$E = \frac{1}{2} \sum_{j=1}^p \left[ \sum_{i=1}^k w_i \phi_i(x_j) - d_j \right]^2, \quad (1)$$

где  $\phi_i(x) = \exp \left[ -\frac{1}{2} [Q_i(x - c_i)]^T [Q_i(x - c_i)] \right]$ ,

матрица  $Q_i$  имеет произвольную структуру.

Нахождение целевой функции (1) обычно производится методом градиентной оптимизации, при этом необходимо, прежде всего, получить вектор градиента целевой функции относительно всех параметров сети. Для расчета градиента можно использовать метод сопряженных графов, позволяющий определять любой компонент градиента на основе анализа исходного или сопряженного с ним графа сети. В качестве источника возбуждения в сопряженном графе выступает разностный сигнал  $(y-d)$ , представляющий величину фактического рассогласования. Конкретные составляющие градиента определяются непосредственно по информации о графах:

$$\frac{\partial E}{\partial w_0} = y - d; \quad (2)$$

$$\frac{\partial E}{\partial w_i} = \exp(-0,5 \cdot u_i) \cdot (y - d); \quad (3)$$

$$\frac{\partial E}{\partial c_j^{(i)}} = \hat{v}_j^{(i)} = \exp(-0,5 \cdot u_i) w_i (y - d) \sum_{k=1}^N Q_{kj}^{(i)} z_k^{(i)}; \quad (4)$$

$$\frac{\partial E}{\partial Q_{kj}^{(i)}} = v_j^{(i)} \hat{z}_j^{(i)} = -\exp(-0,5 \cdot u_i) w_i (y - d) (x_k - c_k^{(i)}) z_j^{(i)}, \quad (5)$$

где  $z_j^{(i)} = \sum_{k=1}^N Q_{kj}^{(i)} (x_k - c_k^{(i)})$ ,  $u_i = \sum_{k=1}^N [z_k^{(i)}]^2$ .

В целях практической реализации нейросетевого прогнозирования будем использовать пакет Statistica Neural Networks, позволяющий моделировать различные типы сетей.

Для обучения использовалась трехслойная нейронная сеть. Первый слой – набор входных параметров работы ГПА:

$x_1$  – давление масла на входе в ГТУ, Па;

$x_2$  – средняя температура за газогенератором (ГГ), °С;

$x_3$  – температура газа на выходе из нагнетателя, °С;

$x_4$  – давление газа на выходе из нагнетателя, Па;

$x_5$  – частота вращения ротора силовой турбина (СТ), об/мин;

$x_6$  – частота вращения ГГ, об/мин;

$x_7$  – давление воздуха за компрессором, Па;

$x_8$  – температура газа за СТ, °С;

$x_9$  – степень повышения давления в нагнетателе;

$x_{10}$  – давление масла смазки нагнетателя, Па.

Выбранные параметры  $x_i$  имеют наибольшую корреляционную взаимосвязь с удельным расходом топливного газа  $E_{\text{тг}}^{\text{ГТУ}}$ , предварительно рассчитанным по параметрам газа в нагнетателе - третий слой.

Скрытый слой может содержать от 1 до N элементов, что как установлено, влияет на точность обучения. На рисунке 1 приведена эволюция нейронной сети за счет расширения скрытого слоя.




Рисунок 1. Эволюция нейронной сети за счет расширения скрытого слоя

Для каждого из 10 возможных архитектур нейронной сети было произведено обучение нейронной сети с оценкой среднеквадратической погреш-

ности обучения. На рисунке 2 приведено распределение погрешностей для различных типов сетей.

Из диаграммы (рисунок 2) следует, что наименьшую погрешность обучения имеет нейронная сеть с 5-ю элементами в скрытом слое, поэтому дальнейшие исследования производилась именно с такой архитектурой нейронной сети.




Рисунок 2. Диаграмма распределения погрешности обучения нейронной сети по методу обратного распространения ошибки

На рисунке 3 представлены зависимости определенные по параметрам газа в нагнетателе и по параметрам ГПА (нейронная модель).

Как видно из рисунка 3 характеристика, полученная с использованием параметров работы ГПА, хорошо соотносится с характеристикой удельного расхода топливного газа, рассчитанной по параметрам газа в нагнетателе, средняя квадратическая погрешность составляет 1,0%.

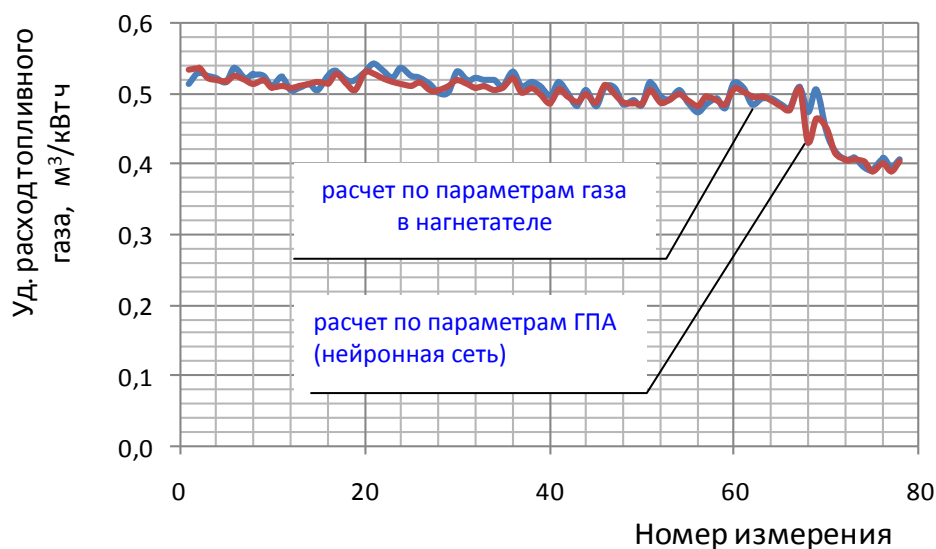


Рисунок 3. Динамика изменения зависимости удельного расхода топливного газа для ГПА №14

Рассмотрим достоверность расчета по данным через 1 месяц эксплуатации ГПА (рисунок 4).

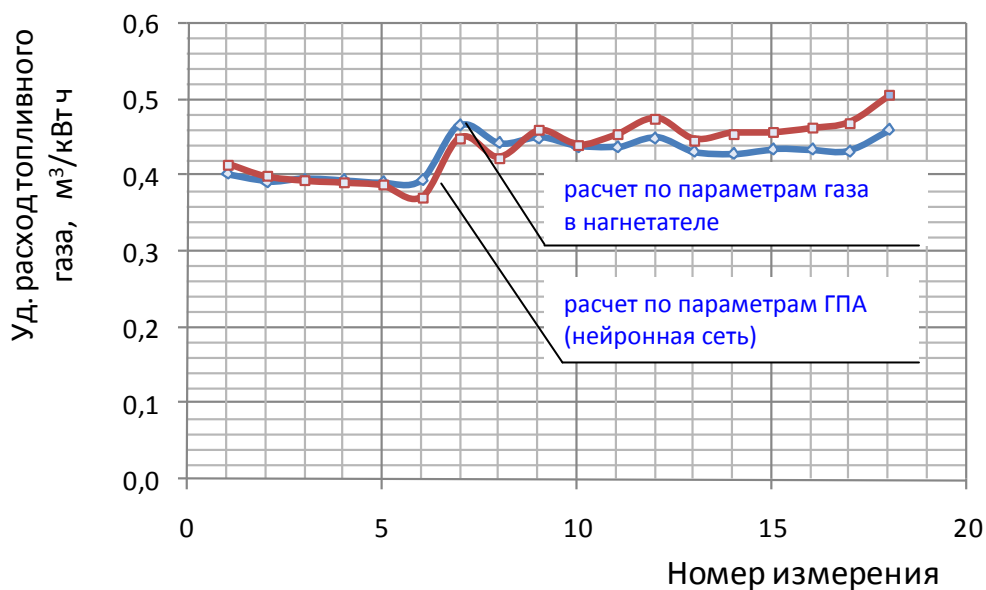


Рисунок 4. Динамика изменения зависимости удельного расхода топливного газа для ГПА №14 через 1 месяц эксплуатации

Из рисунка 4 следует, что средняя квадратическая погрешность составила 4,0%. Вариация удельного расхода топливного газа связана с изменением режима работы агрегата и технического состояния проточной части ГТУ в динамике.



Представляет интерес применение нейронной сети для определения удельного расхода топливного газа другого агрегата – ГПА №15 (рисунок 5).




Рисунок 5. Динамика изменения зависимости удельного расхода топливного газа для ГПА №15

Из рисунка 5 следует, что средняя квадратическая погрешность моделирования составила 4,2% и не увеличилась, по сравнению с агрегатом №14 для которого производилось обучение нейронной сети.

## Выводы

1 На основе проведенных исследований получен и практически обоснован способ определения удельного расхода топливного газа по параметрам работы газоперекачивающих агрегатов, контролируемым штатной системой автоматики с применением нейронных сетей.

2 Предлагаемая нейронная сеть может быть интегрирована в стационарные системы мониторинга компрессорной станции нужно лишь заранее подобрать весовые коэффициенты (обучить нейронную сеть) для используемого типа ГПА.

3 При обучении нейронной сети, по данным с вариацией параметров в обучающей выборке 20%, погрешность обучения не превышает 1%.

4 При использовании обученной нейронной сети для расчета показателей энергоэффективности агрегата для которого производилось обучение и для других агрегатов того же типа, средняя квадратическая погрешность не превышает 5%.

### **Список используемых источников**

1 СТО Газпром 2-3.5-113-2007. Методика оценки энергоэффективности газотранспортных объектов и систем. М.: ООО «Информационно-рекламный центр газовой промышленности», 2007. 55 с.

2 Байков И.Р., Китаев С.В., Шаммазов И.А. Методы повышения энергетической эффективности трубопроводного транспорта природного газа. СПб.: Недра, 2008. 440 с.

3 Ресурсное обеспечение капитального ремонта МГ с учетом технологических показателей эксплуатации машин / Арбузов А.Ю. [и др.] // Газовая промышленность. 2012. №7(678). С. 96-97.

4 Осовский С. Нейронные сети для обработки информации. М: Финансы и статистика, 2004. 344 с.

5 Нейронные сети. STATISTICA Neural Networks: Пер. с англ. М.: Горячая линия – телеком, 2001. 182 с.

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

7 Байков И.Р., Китаев С.В., Шаммазов И.А. Применение нейронных сетей для прогнозирования добычи углеводородного сырья / Известия вузов. Нефть и газ. 2005. № 6. С.60-64.

## References

1 STO Gazprom 2-3.5-113-2007. Metodika otsenki energoeffektivnosti gazotransportnykh obyektov i sistem. M.: OOO «Informatsionno-reklamny tsestr gazovoy promyshlennosti», 2007. 55 s. [in Russian].

2 Baykov I.R., Kitayev S.V., Shammazov I.A. Metody povysheniya energeticheskoy effektivnosti truboprovodnogo transporta prirodno gaza. SPb.: Nedra, 2008. 440 s. [in Russian].

3 Resursnoe obespechenie kapital'nogo remonta MG s uchetom tehnologicheskikh pokazatelej jekspluatacii mashin / Arbuzov A.Ju. [i dr.] // Gazovaya promyshlennost'. 2012. №7(678). S. 96-97. [in Russian].

4 Osovsky S. Neyronnye seti dlya obrabotki informatsii. M: Fi-nansy i statistika, 2004. 344 s. [in Russian].

5 Neyronnye seti. STATISTICA Neural Networks: Per. s angl. M.: Goryachaya liniya – telekom, 2001. 182 s. [in Russian].

6 Kamenev A.S., Korolev S.Yu., Sokotushchenko V.N. Neyromodelirovaniye kak instrument intellektualizatsii energoinformatsionnykh setey. M.: ITs «Energiya», 2012. 124 s. [in Russian].

7 Baykov I.R., Kitaev S.V., Shammazov I.A. Primeneniye neyronnykh setey dlya prognozirovaniya dobyichi uglevodorodnogo syirya, // Izvestiya vuzov. Neft i gaz. 2005. № 6. S.60-64. [in Russian].

## Сведения об авторах

### About the authors

Байков И.Р., д-р техн. наук, профессор, заведующий кафедрой «Промышленная теплоэнергетика», ФГБОУ ВПО УГНТУ, г. Уфа, Российская Федерация

I.R. Baikov, Doctor of Engineering Sciences, professor, Head of the Chair “Heat power industry”, FSBEI HPE USPTU, Ufa, the Russian Federation

Китаев С.В., д-р техн. наук, доцент кафедры «Транспорт и хранение нефти и газа», ФГБОУ ВПО УГНТУ, г. Уфа, Российская Федерация

S.V. Kitaev, Doctor of Engineering Sciences, Associate Professor of the Chair “Transport and Storage of Oil and Gas”, FSBEI HPE USPTU, Ufa, the Russian Federation

E-mail: Svkitayev@mail.ru

Фарухшина Р.Р., аспирант кафедры «Транспорт и хранение нефти и газа», ФГБОУ ВПО УГНТУ, г. Уфа, Российская Федерация

R.R. Faruhshina, post-graduate student of “Transport and storage of oil and gas”, FSBEI HPE USPTU, Ufa, the Russian Federation