

Контроль баланса газа в региональной газотранспортной сети с применением интеллектуальных методов

А. К. Петрова

Санкт-Петербургский государственный электротехнический университет
«ЛЭТИ» им В.И. Ульянова (Ленина)
amsinitca@etu.ru, ak72p@yandex.ru

Аннотация. Повышение эффективности контроля баланса в газотранспортной системе является актуальной задачей. Применение интеллектуальных методов, таких как искусственная нейронная сеть или адаптивная гибридная нейронечеткая система (ANFIS), сочетающая преимущества нейронных сетей и нечеткой логики, может быть таким решением. В статье рассматривается сравнение применения интеллектуальных методов для расчета запаса газа для данных одной из региональных газотранспортных сетей РФ.

Ключевые слова: баланс газа, эффективность газотранспортной сети, нейронная сеть, нечеткая логика, адаптивная гибридная система нечеткого вывода

I. ВВЕДЕНИЕ

Одной из проблем системы учета газа при его транспортировке в системе магистральных газопроводов является небаланс газа [1–3]. Согласно [4], небаланс газа – разница между объемом газа, поступившим и отобраным из системы за отчетный период. Небаланс возникает вследствие влияния множества изменяющихся факторов, в том числе таких, как нелинейно зависимые характеристики рабочей среды (природного газа), оборудования, трубопровода и окружающей среды [5, 6].

В докладе должны быть, как минимум, следующие разделы: обзор литературы, основная часть (методология, результаты), заключение и дальнейшие перспективы исследования.

II. ЗАПАС ГАЗА В МАГИСТРАЛЬНОМ ГАЗОПРОВОДЕ

Одной из составляющих небаланса является величина запаса газа в магистральном трубопроводе, на которую влияют следующие факторы [7]: абсолютное давление и средняя температура, средний коэффициент сжимаемости газа в трубопроводе, а также температура окружающей среды, в которой пролегает газопровод.

Запас газа на участке многониточной системы магистрального газопровода при стандартных условиях определяется по формуле (1):

$$Q = \frac{V \cdot P_{cp} \cdot 293.15}{1.033 \cdot z_{cp} \cdot 10^6 (T_{cp} + 273.15)}, \quad (1)$$

где V – геометрический объем участка газопровода, m^3 ; P_{cp} – среднее давление на участке газопровода, $кгс/см^2$; z_{cp} – средний коэффициент сжимаемости газа на участке газопровода; T_{cp} – средняя температура газа на участке газопровода, $^{\circ}C$.

Геометрический объем трубы на участке вычисляется по формуле:

$$V_i = \frac{D_{вн}^2 L}{4}, \quad (2)$$

где L , $D_{вн}$ – соответственно длина и внутренний диаметр нитки магистрального газопровода.

Среднее давление нитки магистрального газопровода, P_{cp} , $кгс/см^2$, определяется по формуле:

$$P_{cp} = \frac{2}{3} \cdot \left(P_n + \frac{P_k^2}{P_n + P_k} \right), \quad (3)$$

где P_n – абсолютное давление газа в начале участка газопровода, $кгс/см^2$; P_k – абсолютное давление газа в конце участка газопровода, $кгс/см^2$.

Средняя температура участка магистрального газопровода, T_{cp} , $^{\circ}C$, определяется по формуле:

$$T_{cp} = T_o \frac{+T_n - T_o}{L} (1 - e^{-L}) - DP_n^2 - P_k^2 \frac{1 - \left(\frac{1 - e^{-L}}{L} \right)}{2LP_{cp}} \quad (4)$$

где T_n – температура газа в начале участка газопровода, $^{\circ}C$; T_o – температура окружающей среды, в случае пролегания трубопровода в грунте – $T_{гр}$, температура грунта на глубине заложения газопровода, обновляется ежемесячно по статистическим данным; L – длина участка газопровода; α – расчетный коэффициент.

$$0,225 \cdot \left(\frac{K_{cp} d_n}{q C_{cp}} \right) \quad (5)$$

где K_{cp} – средний на участке общий коэффициент теплопередачи от газа в окружающую среду, $Вт/(м^2 \cdot K)$; d_n – наружный диаметр трубы, $мм$; q – расход газа, $млн. м^3/сут$; ρ_v – относительная плотность газа по воздуху; C_p – средняя изобарная теплоемкость газа, $кДж/(кг \cdot K)$.

Усредненное значение коэффициента сжимаемости определяется по формуле:

$$z_{cp} = 10.0907 \cdot P_{cp} \cdot \left(\frac{T_{cp}}{200} \right)^{-3.668} \quad (6)$$

При анализе выражений видно, что каждый компонент формулы (1) определяется, в свою очередь, математической формулой, учитывающей несколько нелинейных факторов, что в совокупности может влиять на корректность и скорость вычислений величины запаса газа, и как следствие, на выявление небаланса газа в

газотранспортной сети. Так, согласно [8] «определение одного из компонентов для расчета α , K_{cp} – среднего на участке общего коэффициента теплопередачи от газа в окружающую среду, признано невыполнимым. Процедура расчета K_{cp} по опытным данным выполняется по модифицированной формуле».

Таким образом, представляется целесообразным исследовать применение других современных методов расчёта запаса газа, в частности интеллектуальных методов, таких как искусственные нейронные сети, нечеткая логика или их сочетание. В данной статье рассматривается применение адаптивной гибридной нейро-нечеткой и нейронной сетей.

III. АДАПТИВНАЯ ГИБРИДНАЯ НЕЙРО-НЕЧЕТКАЯ СЕТЬ

Гибридная нейро-нечеткая сеть представляет собой многослойную нейронную сеть специальной структуры. Обработка информации в нейро-нечеткой сети осуществляется в соответствии с логикой работы нечеткой системы, а настройка параметров – по правилам обучения нейронных сетей. Тем самым объединены преимущества нечеткой логики (по наглядности представления и простоте содержательной интерпретации структуры правил вывода) и нейронных сетей – по возможностям построения и обучения правил нечетких продукций [9–11].

Наибольшее распространение на практике получили гибридные сети, реализованные в форме так называемых адаптивных систем нейро-нечеткого вывода ANFIS (Adaptive Neuro-Fuzzy Inference System) [12].

В работе были использованы статистические данные по запасу газа за 5 месяцев года на участке региональной газораспределительной сети со следующими параметрами:

- 1) давление в трубопроводе P_{cp} , (кгс/см²);
- 2) средняя температура газа в трубопроводе T_{cp} , °C;
- 3) средний коэффициент сжимаемости газа в трубопроводе z_{cp} ;
- 4) запас газа в трубопроводе, $Q_{запас}$, тыс. м³;

Результующим, выходным параметром является запас газа. Остальные параметры – входные.

График изменения результирующего параметра в зависимости от индекса представлен на рис. 1.




Рис. 1. График изменения запаса газа в зависимости от индекса

С использованием среды Matlab [13] к данным были применены различные методы построения гибридной адаптивной нейро-нечеткой системы, при этом набор данных разделен на обучающую и тестовую выборку в

пропорции 70% и 30% исходного датасета соответственно.

A. Генерирование нечетких правил метода решетчатого разбиения (Grid partition)

Согласно этому методу функции принадлежности нечетких термов равномерно распределяются внутри диапазона изменения данных. База знаний содержит все возможные варианты правил. Коэффициенты в заключениях правил принимаются равными нулю [14]. Структура нейро-нечеткой сети на основе метода решетчатого разбиения приведена на рис. 2. В данной модели системой сформировано 81 правило.




Рис. 2. Структура нейро-нечеткой сети на основе метода решетчатого разбиения

График выходной переменной, в зависимости от двух входных переменных изображён на рис. 3.




Рис. 3. Изображение выходной переменной системы нечеткого вывода, для модели, сгенерированной методом решетчатого разбиения

На данном графике $input1 = P_{cp}$, давление в трубопроводе; $input2 = T_{cp}$, средняя температура газа в трубопроводе, $output = Q_{запас}$, запас газа в трубопроводе.

Далее было осуществлено обучение модели. Для обучения нечеткой системы с помощью ANFIS программное обеспечение Matlab использует алгоритм обратного распространения либо отдельно, либо в сочетании с алгоритмом наименьших квадратов. Здесь был использован гибридный метод, состоящий из обратного распространения параметров, связанных с входными функциями принадлежности, и оценки методом наименьших квадратов для параметров, связанных с выходными функциями принадлежности. Количество эпох было выбрано равным 50.

Далее было осуществлено тестирование обученной модели на тестовой выборке. График результатов тестирования представлен на рис. 4. На данном графике более крупными маркерами (снежинками) показаны значения тестовой выборки, маркерами меньшего размера (знаками «плюс») – результат обученной модели.




Рис. 4. Результат тестирования обученной модели, сгенерированной методом решетчатого разбиения

В. Применение правил, заданных методом вычитающей кластеризации (Sub. Clustering)

В основе алгоритма лежит предположение, что каждая экспериментальная точка может быть центром кластера, при этом вначале для каждой точки вычисляется мера правдоподобия данного предположения («потенциал точки»), основанная на плотности точек в заданной окрестности рассматриваемой. Дальнейшие вычисления происходят итеративно [15].

- 1) точка с наибольшим потенциалом объявляется центром первого кластера;
- 2) из отмеченной окрестности этой точки удаляются все остальные точки;
- 3) из оставшихся точек объявляется центр следующего кластера и т.д., пока не будут рассмотрены (исключены или объявлены центрами) все точки.

Структура гибридной сети на основе вычитающей кластеризации показана на рис. 5. В данной модели системой сформировано 28 правил.

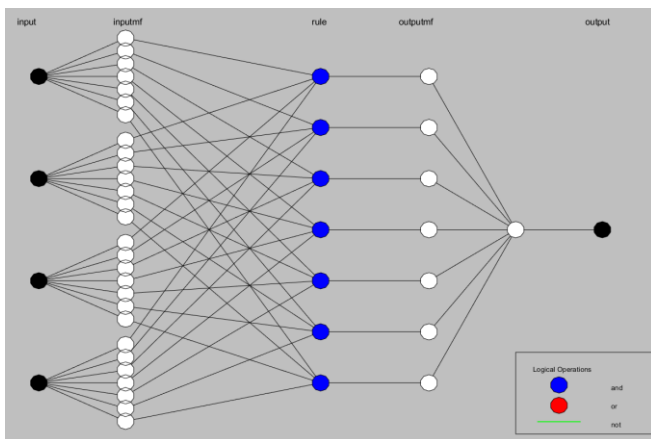


Рис. 5. Структура нейронечеткой сети на основе вычитающей кластеризации

График выходной переменной, в зависимости от двух входных переменных изображен на рис. 6.




Рис. 6. Изображение выходной переменной системы нечеткого вывода, для модели, сгенерированной методом вычитающей кластеризации

На данном графике также $input1 = P_{ср}$, давление в трубопроводе; $input2 = T_{ср}$, средняя температура газа в трубопроводе, $output = Q_{запас}$, запас газа в трубопроводе.

Далее было осуществлено тестирование обученной модели на тестовой выборке. График результатов тестирования представлен на рис. 7. На данном графике более крупными маркерами (снежинками) показаны значения тестовой выборки, маркерами меньшего размера (знаками «плюс») – результат обученной модели.




Рис. 7. Результат тестирования обученной модели, сгенерированной методом вычитающей кластеризации

Результаты применения двух методов генерирования правил показывают, что метод решетчатого разбиения работает более корректно. Результаты сравнения применения методов генерирования правил приведены в табл. 1.

IV. ПРИМЕНЕНИЕ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ

Для более полного сравнения было осуществлено обучение на этих же статистических данных искусственной нейронной сети [16–18]. Ошибка обучения представлена на рис. 8.

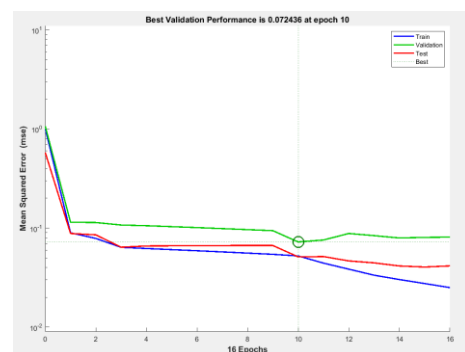


Рис. 8. График ошибки обучения нейросетевой модели

Результаты применения обученной нейронной сети к валидационной и тестовой выборкам, а также сравнение с результатами обучающей выборки приведены на рис. 9.

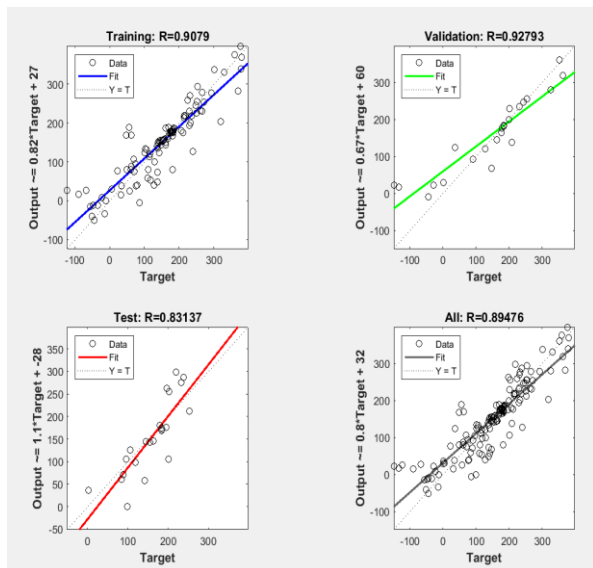


Рис. 9. Результаты применения обученной нейронной сети к валидационной и тестовой выборкам, в сравнении с результатами обучающей выборки

Результаты показывают, что искусственная нейронная сеть более точно описывает зависимость величины запаса газа от входных факторов, по сравнению с гибридными адаптивными нейро-нечеткими сетями.

Результаты сравнения применения интеллектуальных методов приведены в табл. 1.

ТАБЛИЦА 1 РЕЗУЛЬТАТЫ СРАВНЕНИЯ ПРИМЕНЕНИЯ ИНТЕЛЛЕКТУАЛЬНЫХ МЕТОДОВ ДЛЯ РАСЧЕТА ЗАПАСА ГАЗА

Методы	Параметры моделей		
	Ошибка обучения	Ошибка теста	Число правил модели
Метод решетчатого разбиения	1.7	2.59	81
Метод вычитающей кластеризации	2.9	3.14	7
Двухслойная искусственная нейронная сеть	0.01	0.28	-

V. ЗАКЛЮЧЕНИЕ

В рамках работы проведено исследование возможности определения величины запаса газа с применением адаптивной гибридной нейро-нечеткой сети. Осуществлено сравнение методов генерирования нечетких правил методами решетчатого разбиения и вычитающей кластеризации. Результаты показали, что из гибридных сетей более точной является сеть, полученная на основе метода решетчатого разбиения, однако наиболее точной оказалась искусственная нейронная сеть.

В перспективе предполагается повышение качества модели за счет использования расширения и обработки обучающей выборки и совершенствования базы нечетких правил, построение модели регулятора основе нечеткой логики, а также сравнение результатов применения нейро-нечетких моделей с результатами построения моделей регрессии на основе искусственных нейронных сетей.

СПИСОК ЛИТЕРАТУРЫ

- [1] Игнатьев А.А. Оценка причин разбаланса объемов газа в системе «поставщик – потребитель» // Газовая промышленность. 2010. № 6. С. 20–22.
- [2] Саликов А.Р. Разбаланс в сетях газораспределения // Газ России. 2015. № 4. С. 36–41.
- [3] Unaccounted for gas in natural gas transmission networks: Prediction model and analysis of the solutions / F. Arpino, M. Dell'Isola, G. Ficco, P. Vigo // J. of Natural Gas Science and Engineering. 2014. Vol. 17. P. 58–70.
- [4] Информационное письмо Федеральной службы по тарифам (ФСТ) от 28.06.2005 г. Исх. № СН-3923/9 «Об учете потерь газа».
- [5] Даев Ж.А. Система автоматического контроля разбалансов объема природного газа на основе нейронечеткой модели: Автоматизация, телемеханизация и связь в нефтяной промышленности 3(548) 2019 С. 37-40
- [6] Хворов Г.А., Козлов С.И., Аكوпова Г.С., Евстифеев А.А. Сокращение потерь природного газа на основе транспортировке по магистральным газопроводам ОАО «Газпром» // Газовая промышленность. 2013. № 12. С. 66–69.
- [7] СТО ГАЗПРОМ 2-3.5-051-2006 Нормы технологического проектирования магистральных газопроводов.
- [8] Слободчиков К.Ю. Метод формирования расчетных примеров для диспетчерских задач транспорта газа // Газовая Промышленность 2018; 3:78-86
- [9] Заде, Л.А. Основы нового подхода к анализу сложных систем и процессов принятия решений / Л.А. Заде // Математика сегодня: Сборник статей; пер. с англ. М.: Знание, 1974. – С.5-49 р.
- [10] Штобба, С.Д. Введение в теорию нечетких множеств и нечеткую логику -<http://matlab.exponenta.ru/fuzzylogic/book1/index.php>
- [11] Ярушкина П.Л. Основы теории нечетких и гибридных систем: учеб. пособие / П.Л. Ярушкина. Москва: Финансы и статистика, 2009. 320 с.
- [12] Назаров А.В., Лоскутов А.А. Нейросетевые алгоритмы прогнозирования и оптимизации систем: Наука и Техника, СПб, 2003, 384 с.
- [13] Дьяконов В.П., Круглов В.В. MATLAB 6.5 SP1/7/7 SP1/7 SP2 + Simulink 5/6. Инструменты искусственного интеллекта и биоинформации. М.: СОЛОН-ПРЕСС, 2006.
- [14] Усков А.А., Кузьмин А.В. Интеллектуальные технологии управления. Искусственные нейронные сети и нечеткая логика. М.: Горячая линия - Телеком, 2004. 143 с.
- [15] Chiu S., "Fuzzy Model Identification Based on Cluster Estimation" // *Journal of Intelligent & Fuzzy Systems*, Vol. 2, No. 3, Sept. 1994.
- [16] Дилигенский Н.В., Дымова Л.Г., Севастьянов П.В. Нечеткое моделирование и многокритериальная оптимизация производственных систем в условиях неопределенности: технология, экономика, экология М.: «Издательство Машиностроение – 1», 2004.
- [17] A. Vellidoa, P.J.G. Lisboaa, J. Vaughanb Neural networks in business: a survey of applications (1992–1998): *Expert Systems with Applications* 17 (1999) 51–70
- [18] Хайкин С. *Нейронные сети. Полный курс*. Вильямс, 2018.