

ПРОГНОЗИРОВАНИЕ ЗАГРЯЗНЕНИЯ ЛОПАТОК ОСЕВОГО КОМПРЕССОРА ГАЗОПЕРЕКАЧИВАЮЩЕГО АГРЕГАТА С ИСПОЛЬЗОВАНИЕМ НЕЙРОСЕТЕВЫХ СТРУКТУР

Влацкая И.В., Максименко А.В.

Оренбургский государственный университет, г. Оренбург

В связи с увеличением себестоимости транспорта газа в стране одним из важнейших направлений разработки считается работа по снижению затрат на трубопроводный транспорт газа. Одним из вариантов решения является повышение эффективности обслуживания расположенных на компрессорных станциях газоперекачивающих агрегатов, существенную часть которых составляют газоперекачивающие агрегаты с газотурбинным приводом (ГПА).

Формирование комплекса обслуживающих мероприятий по обеспечению работоспособности ГПА, в том числе и проведения периодических чисток осевого компрессора, базируется на плановом подходе. При этом нормативы на межремонтные периоды для оборудования, не выработавшего максимальный установленный рабочий ресурс, не учитывают фактическое состояние технического парка предприятий газового комплекса, что во многих случаях ведёт к неоправданным расходам при его эксплуатации.

Существующие системы управления ГПА содержат отдельные элементы для фиксации технических параметров оборудования (мониторинга), однако не имеют подсистем идентификации технического состояния ГПА на основе анализа параметрической информации. В связи с этим, эксплуатация газоперекачивающего оборудования с загрязнением лопаток осевого компрессора ведет к его преждевременному износу, перерасходу топливного газа и, как следствие, существенному финансовому ущербу и снижению эффективности работы предприятия в целом.

Также следует отметить, что проведение чистки осевого компрессора приводит не только к положительным эффектам (среди которых повышение мощности и снижение расхода топливного газа), но и к уменьшению межремонтного периода и повышению вероятности отказа оборудования [1].

Таким образом, эффективное решение задачи идентификации технического состояния требует построения модели изменения технического состояния для каждого отдельного агрегата с учетом индивидуальной динамики технического состояния и возможности коррекции данной модели с течением времени.

Загрязнение проточной части осевого компрессора может привести к уменьшению расхода воздуха до 6% и КПД осевого компрессора на 2-3%, что вызывает снижение полезной мощности агрегата до 10% [2].

Из сказанного выше следует, что очистки проточной части газоперекачивающего агрегата (ШПА) играют двоякую роль. С одной стороны, они позволяют значительно сократить расход топливного газа, с другой – приводят к дополнительной вероятности возникновения отказов оборудования.

Таким образом, представляется актуальной задача разработка модели изменения технического состояния газоперекачивающих агрегатов на основе анализа параметрической информации.

В качестве основы модели изменения технического состояния в нашей работе предлагается использовать нейронные структуры, а именно двунаправленную ассоциативную память.

Двунаправленная ассоциативная память (ДАП) является гетероассоциативной; входной вектор поступает на один набор нейронов, а соответствующий выходной вектор вырабатывается на другом наборе нейронов. ДАП способна к обобщению, вырабатывая правильные реакции, несмотря на искаженные входы. Кроме того, могут быть реализованы адаптивные версии ДАП, выделяющие эталонный образ из зашумленных экземпляров.

Гроссберг показал преимущества использования сигмоидальной (логистической) функции активации [4]

$$OUT_i = \frac{1}{1 + \exp(-\lambda NET_i)}$$

где OUT_i – выход нейрона i , NET_i – взвешенная сумма входных сигналов нейрона i , λ – константа, определяющая степень кривизны.

Немодифицированная ДАП стандартной конфигурации имеет ограничения на максимальное количество ассоциаций, которые она может точно воспроизвести. Число воспроизводимых образов L при использовании n нейронов не может превышать величины $n/(2 \log_2 n)$.

Для повышения фактической емкости нейронной сети, традиционную схему организации ДАП предлагается модифицировать, добавлением дополнительных слоев сети (слои с номерами 0.5 и 1.5). Слой с номером 0,5 является клеточным слоем нейронной сети.

Отличительной особенностью клеточного слоя является возможность взаимодействия соседних клеток внутри самого слоя.

Соседними нейронами клеточного слоя будем считать нейроны $\alpha_1 = (i_1; j_1)$ и $\alpha_2 = (i_2; j_2)$ если $\rho(\alpha_1, \alpha_2) = \max\{|i_1 - i_2|, |j_1 - j_2|\}$

Некоторая клетка α описывается в момент времени $t \geq 0$ двумя величинами:

$V_\alpha(t)$ – мембранным потенциалом

$X_\alpha(t)$ - состоянием активности

$$X_\alpha(t) = \Theta[V_\alpha(t) - V_\alpha^*]; \Theta(V) = \begin{cases} \Theta(V) = 1; & V \geq 0 \\ \Theta(V) = 0; & V < 0 \end{cases}$$

где V_α^* - порог активации клетки.

Клетки, для которых $X_\alpha(t) = 1$ считаются активными, а при $X_\alpha(t) = 0$ считаются заторможенными. В классических моделях нейронных сетей, основанных на биологическом принципе передачи импульса по аксону от одного нейрона на другой, мембранный потенциал клетки определяется как

взвешенная (по синаптическим весам) сумма состояний активности соседних клеток.

При электрической связи между нейронами, мембраны которых тесно соприкасаются, результирующий потенциал клетки и, соответственно, динамика изменения выглядят иначе. Рассмотрим для клетки α следующие характеристики: C – емкость, $Q_\alpha(t)$ – заряд, $I_\alpha(t)$ – выходной ток, $R_{\alpha\beta} = R_{\beta\alpha}$ – сопротивление синаптической связи между клетками α и β . Величина выходного тока $I_\alpha(t)$ определяется выражением

$$I_\alpha(t) = \sum_{\beta:p(\alpha,\beta)\leq 1} \frac{1}{R_{\alpha\beta}} [V_\beta(t) - V_\alpha(t)].$$

Поскольку $Q_\alpha = CV_\alpha$, уравнение динамики мембранного потенциала клетки принимает вид:

$$\Delta V_\alpha = \sum_{\beta:p(\alpha,\beta)\leq 1} A_{\alpha\beta} [V_\beta(t) - V_\alpha(t)];$$

$$A_{\alpha\beta} = (CR_{\alpha\beta})^{-1}$$

В нашем случае клеточный слой описывается двумерным массивом клеток $\alpha = (i, j) \in I \times J$

В этом случае окончательная динамика клеточного слоя принимает вид:

$$\Delta V_\alpha = \sum_{\beta:p(\alpha,\beta)\leq 1} A_{\alpha\beta} [V_\beta(t) - V_\alpha(t)], V_\alpha(0) = V_\alpha^0, \alpha \in I \times J$$

$$X_\alpha(t) = \Theta[V_\alpha(t) - V_\alpha^*], \alpha \in I \times J$$

В итоговом варианте ассоциативная структура выглядит следующим образом: входной вектор A предварительно поступает в соответствующее нейроны клеточного слоя (слоя 0,5), в котором согласно установленным правилам $NetK(A)$ проводится изменение состояния исходного вектора и затем данный вектор обрабатывается матрицей весов W сети (слой 1), в результате чего вырабатывается вектор выходных сигналов нейронов B .

Вектор B затем обрабатывается матрицей весов $W_{1.5}$, в результате чего вырабатывается вектор выходных сигналов нейронов $B_{1.5}$. Далее вектор $B_{1.5}$ обрабатывается транспонированной матрицей W^t весов сети, которая вырабатывает новые выходные сигналы, представляющие собой новый входной вектор $A_{1.5}$.

В векторной форме:

$$b_i = F(\sum_j Net(a_j)w_{ij}); \quad b_{1.5,i} = G(\sum b_i W_{1.5,i}); \quad a_{1.5,i} = F(\sum_j b_{1.5,j} w'_{ij})$$

Для решения задачи верификации был использован программный продукт MatLab и пакет библиотек NNTools. Для проверки соответствия была построена трехслойная нейронная сеть с обратным распространением ошибки и логистической функцией активации[5,6].

На основе данных о проводимых очистных мероприятиях для отдельных ГПА, а также исходя из предположения о сохранении динамики ФТС рассчитывается период переработки ГПА, представляющий собой вектор значений:

$$D = (\Phi TC_b, V_2, i); I = (k+1) .. n, \quad (14)$$

где i – число элементов массива; D – массив фактических замеров параметров работы ГПА после достижения порогового значения ФТС; k – номер фактического замера параметров работы ГПА, на котором достигается пороговый уровень ФТС; n – общее число замеров; ΦTC_i – значение функции технического состояния на i -м шаге наблюдения; $V_{г,i}$ – объем расхода топливного газа на i -м шаге наблюдения.

Таким образом, на основании построенного массива D для отдельных процессов наблюдения рассчитаны показатели перерасхода топливного газа и, соответственно, предполагаемые объемы экономии топливного газа при внедрении указанного программного средства:

$$V_{г,эк} = \sum_{i=k+1}^n (V_{г,i} - V_k), \quad (15)$$

где $V_{г,эк}$ – объем экономии топливного газа и V_k – объем расхода топливного газа ГПА на момент достижения порогового значения.

В качестве экспериментальных данных использована информация, собираемая разработанной подсистемой из различных электронных документов в процессе функционирования ГПА, а также данные о проведении обслуживающих мероприятий в плановом режиме. В качестве порогового значения ФТС было выбрано значение $\Phi TC_{порог} = 0,72$, т.к. было установлено существенное снижение эффективности очистных мероприятий после преодоления указанного уровня. Результаты проведенного исследования, а также достигаемая экономия топливного газа при использовании разработанной системы для 24-часового окна прогнозирования приведены в таблице 1.

Таблица 1 - Результаты исследования точности прогнозирования и объемы экономии топливного газа для различных периодов функционирования

Результаты, полученные для межсезонного периода эксплуатации		Результаты, полученные для зимнего и летнего периодов эксплуатации	
Достигнутая точность (24 ч.)	Экономия топливного газа (м ³)	Достигнутая точность (24 ч.)	Экономия топливного газа (м ³)
91 %	3750	95 %	1673
93 %	1657	96 %	1890
93 %	2534	96 %	2130
89 %	672	94 %	2670
88 %	3575	90 %	2790
94 %	3818	94 %	970
93 %	1820	92 %	1250

Для зимнего периода функционирования ГПА показатель точности прогнозирования достигает 96 %.

Межсезонный период характеризуется существенными нерегулярными возможными скачками параметрических данных и наиболее сложен для

прогнозирования ФТС. Точность прогнозирования в указанное время достигает минимальных значений (88 %), по сравнению с другими периодами, значений.

Летний период работы ГПА характеризуется стабильными внешними условиями и определенными суточными колебаниями ряда параметрических показателей, что способствует повышению точности прогнозирования в ряде случаев до 92 %.

При проведении исследований и формировании таблицы результатов учитывались расчетные затраты расхода газа на проведение очистных мероприятий в 3000 м³. По результатам исследований установлена предполагаемая экономия топливного газа в пределах от 800 до 4000 м³. Для оценки адекватности использовался статистический коэффициент детерминации $R^2 = 0,89$.

Достигается удовлетворительное, по сравнению с ДАП стандартной конфигурации увеличение емкости ассоциативной памяти, достаточное для решения рассматриваемой задачи. Возможность коррекции весов нечеточных слоев сети обеспечивает гибкость модели и возможность коррекции при изменении условий эксплуатации или скорости загрязнения лопаток осевого компрессора.

Список литературы

1. Козаченко А.Н. Эксплуатация компрессорных станций магистральных газопроводов.— М.: Нефть и газ, 1999,— 463 с.
2. Щуровский В.А., Левыкин А.П. Загрязнения и очистка проточных частей осевых компрессоров газотурбинных установок. М., ВНИИЭГАЗПром. Обз. информация. Серия -Транспорт и хранение газа. 1986,- вып. 11, с. 28.
3. Байков И.Р., Смородов Е.А., Ахмадулин К.Р. Методы анализа надежности и эффективности систем добычи и транспорта углеводородного сырья – М: ООО «Недра - Бизнесцентр», 2003. – 275 с.
4. Уоссермен Ф. Нейрокомпьютерная техника: Теория и практика Пер. с англ. Зуев Ю.А. Точенов. В.А. М: «Мир» 1992. – 184 с.
5. Влацкая И. В., Максименко А. В. Повышение эффективности эксплуатации газоперекачивающих агрегатов газоконпрессорных станций. Проблемы экономики и управления предприятиями, отраслями, комплексами: монография. – Книга 23. – Новосибирск: Издательство ЦРНС, 2013. – С. 270-307.
6. Максименко, А. В. Моделирование процесса загрязнения лопаток осевого компрессора с использованием нейросетевых структур. Образование. Наука. Научные кадры. – 2014. – №1. – С. 243-246.