

И.Р. Байков, С.В. Китаев, И.А. Шаммазов,

Уфимский государственный нефтяной технический университет, ООО «Баштрансгаз»

МОДЕЛИРОВАНИЕ РАБОТЫ ГАЗОВЫХ ПРОМЫСЛОВ НА ОСНОВЕ НЕЙРОННЫХ СЕТЕЙ

Использование достижений научно-технического прогресса в газовой промышленности в последнее время приобретает актуальный характер и тесно связано с развитием отрасли.

Наиболее значимыми объектами, требующими особого внимания, как на стадии разработки, так и на стадии эксплуатации являются газовые промыслы в связи с нестационарностью режима добычи газа. В условиях нестационарности условий добычи газа меняются и режимы работы дожимных компрессорных станций (ДКС), обеспечивающих повышение давления газа до давления в магистральном газопроводе (МГ).

На первом этапе работы ДКС компримирование осуществляется в одну ступень. По мере снижения устьевого давления переходят на двухступенчатое компримирование. На переходных режимах используют энергоэффективные режимы работы энергопривода ДКС исходя из условия работы оборудования в зоне максимальных коэффициентов полезного действия (к.п.д.).

Главным показателем, от которого зависит режим работы дожимных компрессорных станций, является объем добычи газа. На основе спрогнозированных величин добычи газа разрабатывается карта рациональных режимов работы оборудования, позволяющая повысить оперативность выбора энергоэффективных режимов работы ДКС.

Специфической особенностью добычи углеводородного сырья является технологическая структура месторождений, представляющая собой разветвленную сеть сборных газопроводов малого диаметра, переходящих в единый коридор магистральных газопроводов.

Целью данной работы является разработка метода прогнозирования добычи природного газа в целом по месторождению на основе использования данных месячных объемов добываемого газа.

В качестве экспериментальных данных использовались объемы помесечной добычи газа за пятилетний период эксплуатации одного из северных промыслов Сенюманской залежи. На рис. 1 представлена помесечная динамика добычи газа за 2000 г. по 15 ДКС. Из результатов следует наличие значимой корреляции между зависимостями, которая составляет 0,96-0,99. Из рисунка также следует не высокая вариация суточной и месячной неравномерности добычи, поэтому следует ожидать достаточно высокую достоверность результатов прогноза.

В настоящее время традиционно используются алгоритмы прогнозирования, основанные на применении мето-

дов математической статистики, теории распознавания образов и синергетики [1]. Отличительной особенностью всех этих алгоритмов является необходимость выявления временных характеристик прогнозируемых показателей. Однако их применение ограничено сравнительно простыми системами, а срок прогноза - несколькими шагами во времени. В нашем случае при рассмотрении газового промысла как сложной технической системы, состоящей из нескольких ДКС и сборных газопроводов, методы прогнозирования одномерных временных рядов приводят к существенной погрешности. В связи с этим, требуется дополнительный метод прогнозирования.

В последнее время широкое применение находят нейронные сети (НС) [2]. Нейронные сети – это раздел искусственного интеллекта, в котором для обработки сигналов используются явле-




Рисунок 1

ния, аналогичные происходящим в нейронах живых существ. Важнейшая особенность сети, свидетельствующая о ее широких возможностях и огромном потенциале, состоит в параллельной обработке информации всеми звеньями. При громадном количестве межнейронных связей это позволяет ускорить процесс обработки информации. Кроме того, при большом количестве межнейронных соединений сеть приобретает устойчивость к ошибкам, возникающим на некоторых линиях. Функции поврежденных связей берут на себя исправные линии, в результате чего деятельность сети не претерпевает существенных возмущений. Каждый нейрон характеризуется своим текущим состоянием по аналогии с нервными клетками головного мозга, которые могут быть возбуждены или заторможены. Он обладает группой синапсов – однонаправленных входных связей, соединенных с выходами других нейронов, а также имеет аксон –

выходную связь данного нейрона, с которой сигнал (возбуждения или торможения) поступает на синапсы следующих нейронов. Общий вид нейрона приведен на рис. 2.

Каждый синапс характеризуется величиной синаптической связи или ее весом w_i , который по физическому смыслу эквивалентен электрической проводимости.

Текущее состояние нейрона определяется, как взвешенная сумма его входов:

$$S = \sum_{i=1}^n x_i w_i \quad (1)$$

Выход нейрона есть функция его состояния: $y = f(s)$

Основу обучения НС представляет целевая функция, формулируемая, как правило, в виде квадратичной суммы разностей между фактическими и ожидаемыми значениями выходных сигналов. В случае единичной обучающей выборки (x, d) целевая функция определяется в виде

$$E(w) = \frac{1}{2} \sum_{k=1}^m (y_k - d_k)^2 \quad (2)$$

При большем количестве обучающих выборок j ($j=1, 2, 3, \dots, p$) целевая функция превращается в сумму по всем выборкам

$$E(w) = \frac{1}{2} \sum_{j=1}^p (y_k^{(j)} - d_k^{(j)})^2 \quad (3)$$

Если принять, что целевая функция непрерывна, то наиболее эффективными способами обучения оказываются градиентные методы оптимизации, согласно которым уточнение вектора весов (обучение) производится по формуле $w(k+1) = w(k) + \Delta w$ (4) где $\Delta w = \eta p(w)$ η – коэффициент обучения; $p(w)$ – направление в многомерном пространстве w .

Обучение многослойной сети с применением градиентных методов требует определения вектора градиента относительно весов всех слоев сети, что необходимо для правильного выбора направления $p(w)$. Эта задача имеет оче-



Возможно изготовление труб с прорезями под ключ и без

Трубы бурильные с приварными замками для ремонта нефтегазодобывающих скважин

О Т К Р Ы Т О Е А К Ц И О Н Е Р Н О Е О Б Щ Е С Т В О

ЗАВОД БУРОВОГО ОБОРУДОВАНИЯ

г. Оренбург, пр. Победы, 118
e-mail: zbo@pochta.ru

тел.: +7 (3532) 75-42-67, 75-68-14
факс: +7 (3532) 75-42-73, 75-68-19

www.zbo.ru

Трубы бурильные с приварными замками для геофизических изысканий при поиске и разведке нефти и газа; для бурения разведочных скважин на воду и твердые полезные ископаемые






Рисунок 2

видное решение только для весов выходного слоя. Для других слоев создана специальная стратегия, которая в теории искусственных НС называется алгоритмом обратного распространения ошибки [2], являющимся процедурой обучения сети.

Представленная схема может быть использована для решения прикладных задач в газовой промышленности. На основании вышеизложенного рассмотрим задачу прогнозирования добычи углеводородного сырья по промыслам. На рис. 3 представлена структура НС применительно к промыслам одного из северных месторождений которая имеет аналогию с искусственным нейроном (рис. 2). Используем обозначения, представленные на рис. 3. Обозначив буквой n – число месяцев в обучающей выборке, $k = n - 1$, m – количество пунктов учета добываемого газа.

Имея в наличии временные ряды значений, представляющих собой месячную добычу газа по пятнадцати ДКС целевая функция будет задаваться формулой (3). С учетом обозначений введенных на рис. 3, функция определится выражением

$$Q = \frac{1}{2} \sum_{j=1}^m \left[f \left(\sum_{i=1}^k w_{ij} q_i \right) - d_j \right]^2 \quad (5)$$




Рисунок 4




Рисунок 3

Конкретные компоненты градиента рассчитываются дифференцированием зависимости (5). При этом подбираются веса нейронов выходного слоя. Для выходного слоя получим

$$\frac{\partial Q}{\partial w_{ij}} = (y_i - d_i) \frac{df(u_i)}{du_i} q_j \quad (6)$$

где

$$u_i = \sum_{j=1}^k w_{ij} q_j$$

Если ввести обозначение

$$\delta_i = (y_i - d_i) \frac{df(u_i)}{du_i},$$

то соответствующий компонент градиента относительно весов нейронов выходного слоя можно представить в виде

$$\frac{\partial Q}{\partial w_{ij}} = \delta_i q_j \quad (7)$$

Описание градиента представляется произведением двух сигналов: первый соответствует начальному узлу данной взвешенной связи, а второй величине погрешности, перенесенной в узел, с которым эта связь установлена.

Эффективность прогнозирования оценивалась показателем процентной погрешности [2], рассчитываемой по формуле:

$$\varphi = \frac{1}{n} \sum_{i=1}^n \frac{|Q - \bar{Q}|}{Q} \cdot 100\% \quad (8)$$

где \bar{Q} – прямо спрогнозированное значение добычи газа;

Q – фактическая месячная добыча газа; n – количество ДКС, оборудованных узлами учета.

Используя данные месячной добычи углеводородного сырья за пятилетний период произведем анализ возможности применения НС (рис. 3) для прогнозирования объемов добычи газа в целом по месторождению. Обучение НС

будем производить первоначально по выборке за 2000 г., далее объем обучающей выборки будем увеличивать на годовой промежуток. Результаты оценки погрешностей прогноза добычи углеводородного сырья нейронными сетями обученными по выборкам различного объема представлены на рис. 4. Из рисунка следует, что с увеличением объема обучающей выборки достоверность прогноза увеличивается.

Таким образом, на основе проведенных исследований применения нейронных сетей для прогнозирования добычи углеводородного сырья можно сделать следующие выводы. С увеличением объема обучающей выборки повышается точность прогноза. Наибольшая достоверность прогноза достигается при использовании нейронной сети обученной по данным за четыре года, погрешность при этом составляет не более 2,5%.

ЛИТЕРАТУРА

1. Байков И.Р., Смородов Е.А., Ахмадуллин К.Р. Методы анализа надежности и эффективности систем добычи и транспорта углеводородного сырья. - М.: ООО «Недра - Бизнесцентр», 2003. - 275 с.
2. Осовский С. Нейронные сети для обработки информации/Пер. с польского И.Д. Рудинского.-М.: Финансы и статистика, 2004.-344 с.