

СИСТЕМНЫЙ АНАЛИЗ, УПРАВЛЕНИЕ И ОБРАБОТКА ИНФОРМАЦИИ

УДК 681.5:621

Ю. И. ЗОЗУЛЯ, А. А. ЖИЛЬЦОВ, Ю. С. КАБАЛЬНОВ

**СИСТЕМНАЯ ИНТЕГРАЦИЯ
НЕЙРОСЕТЕВЫХ АНАЛИЗАТОРОВ
ПРИ ДИАГНОСТИКЕ СОСТОЯНИЯ ИНЖЕНЕРНЫХ СЕТЕЙ**

Предложены многомерные балансные и диагностические модели и программные средства анализа баланса потоков в инженерных сетях, применительно к области нефтегазодобычи. Модели реализуются в нейросетевом базисе в виде множества локальных нейросетевых анализаторов данных реального времени с кусочно-линейной и кусочно-квадратичной аппроксимацией разделяющих функций. Диагностика состояния инженерных сетей осуществляется в процессе многоуровневой системной интеграции (метаинтеграции) локальных нейросетевых анализаторов с учетом результатов проверки гипотез о причинах возникновения дисбалансов потоков в узлах инженерной сети. Нейросетевые модели генерируются на основе описания графа инженерной сети, имеющегося в базе данных программного комплекса нефтяного промысла. *Нефтяной промысел ; инженерная сеть ; баланс потоков ; данные реального времени ; причина возникновения дисбаланса потоков ; диагностика состояния ; гипотеза ; потоковая модель ; нейронная сеть ; обратное распространение ошибки ; идентификация ; анализатор ; метаинтеграция*

ВВЕДЕНИЕ

Решение многих проблем оперативного контроля и диагностики состояния объектов нефтяного промысла (блоков нефтяного пласта, скважин, замерных и технологических установок, трубопроводов) сводится к исследованию дисбалансов газожидкостных потоков в узлах инженерных сетей (ИС) и к выявлению причин дисбалансов с получением оценок распределения потоков в сети.

На нефтяном промысле анализ баланса выполняется на основе результатов измерения параметров многокомпонентных газожидкостных потоков в условиях существенной неполноты и противоречивости исходных данных как о структуре и состоянии технологических объектов ИС нефтегазодобычи, так и о состоянии используемых средств измерения. Возникающие в процессе анализа значительные погрешности в оценивании значений параметров и грубые ошибки в диагностике состояния ИС (gross errors) приводят к прямым экономическим потерям и снижению эффективности управления разработкой месторождений. Особенно существенны эти ошибки на завершающей стадии разработки месторождений, когда из-за ошибок в определении состояния объектов нефтегазодо-

бычи не правильно осуществляется оперативное планирование технологических режимов и организационно-технологических мероприятий, что ведет к значительному росту обводненности продукции скважин.

**1. МОДЕЛИРОВАНИЕ
ИНЖЕНЕРНЫХ СЕТЕЙ**

Теоретические вопросы моделирования ИС, оценивания распределения потоков, идентификации параметров и диагностики состояния ИС с использованием известных механико-математических моделей в отечественной литературе исследовались в работах А. Г. Евдокимова, А. П. Меренкова, В. Я. Хасилева и др. [1–4], за рубежом – в работах А. Soudek [5]. Однако практическое применение этих моделей и основанных на них методов (model-based methods) при анализе состояния и идентификации параметров ИС нефтегазодобычи, затруднено ввиду сложности процессов нефтегазодобычи, неполноты собираемых данных реального времени и наличия большого числа неучтенных факторов.

С появлением технологий искусственного интеллекта, при обработке и интерпретации данных реального времени все большее значение приобретают методы, основанные на знаниях (knowledge-based methods) [6]. Их применение для

анализа состояния объектов нефтегазодобычи связано с использованием разнообразных дополнительных априорных и опытных данных о функционировании и нарушениях в работе ИС, имеющих детерминированный или случайный характер.

Одними из наиболее перспективных среди этих методов являются нейросетевые методы. Они позволяют организовать параллельные вычисления, автоматически генерируя в нейросетевом вычислительном базисе адаптивные модели объектов нефтегазодобычи, параметры которых могут быть найдены на основе неполных и противоречивых данных реального времени с использованием известных алгоритмов обучения нейронных сетей [7].

В рамках существующих подходов к идентификации параметров и диагностике состояния ИС на основе нейронных сетей, известные механико-математические модели комбинируются с множеством раздельно обучаемых нейросетевых моделей элементов ИС как «черных ящиков» с заданной архитектурой нейронных сетей, которые имеют большое число настраиваемых параметров (весов связей между нейронами). При определении структурно-функциональной организации нейронных сетей таких «черных ящиков» и связей между ними обычно не учитывается известная структура физических моделей этих объектов [8] и соответственно не выполняется структурная и параметрическая идентификация их параметров. Поэтому результаты обучения нейронных сетей не удается четко интерпретировать в терминах физических теорий, описывающих гидравлические процессы [9].

В то же время использование структурированных полностью нейросетевых моделей («серых ящиков»), в организации которых находят отражение знания об известных законах, характеризующих зависимости между физическими параметрами состояния сложного технического объекта, позволяет осуществлять раздельную идентификацию параметров его физического состояния путем управления процессами обучения отдельных нейронов и связей между ними. Результаты обучения отдельных нейронов структурированной нейросетевой модели в этом случае могут быть интерпретированы в терминах физических теорий и использованы для повышения эффективности интеллектуального контроля, диагностики и управления сложным техническим объектом [10].

В данной работе осуществляется обобщение и распространение подобного подхода на разработку структурированных полностью нейросе-

тевых моделей ИС нефтегазодобычи. Анализ состояния отдельных участков и объектов ИС реализуется с помощью локальных нейросетевых анализаторов, обеспечивающих диагностику и согласование данных реального времени (data reconciliation) путем управления контуром обучения нейронных сетей и отдельных нейронов, находящихся в составе анализаторов [11]. Решается задача многоуровневой системной интеграции (метаинтеграции) отдельных нейросетевых анализаторов данных реального времени путем структурированного и совместного (согласованного) обучения их нейронных сетей [12], с выработкой рекомендаций и методик применения нейросетевых технологий для анализа баланса многокомпонентных потоков ИС на нефтяных промыслах [13].

2. УРАВНЕНИЯ БАЛАНСНОЙ МОДЕЛИ

В рамках традиционных информационных технологий анализа баланса потоков структура ИС нефтегазодобычи, имеющих в своем составе отдельные участки и объекты, объединенные многокомпонентными газо-жидкостными потоками (нефть, газ, вода, механические и другие примеси), представляется оргграфом $G(N, M)$, где M – множество вершин, N – множество ребер (дуг) графа. Вершине графа ставится в соответствие узел ИС, ребру графа – один из входных или выходных потоков узла. Согласование результатов измерений осуществляется с использованием метода взвешенных наименьших квадратов, с учетом класса точности используемых средств измерения параметров потоков [5].

Балансные модели инженерных сетей, кроме системы уравнений баланса потоков, которые свойственны потоковым моделям (flow model) [5],

$$Q = BX, \quad (1)$$

где Q – вектор притоков (утечек, потерь) в узлах ИС; B – матрица баланса, соответствующая матрице инцидентности графа сети; X – вектор состояния (распределение потоков) сети, содержит систему уравнений связи между вектором состояния сети X и вектором результатов измерения параметров состояния сети Y

$$X = F(Y) + V, \quad (2)$$

де $F(Y)$ – нелинейная векторная функция связи; V – вектор погрешностей измерений.

Поток, соответствующий j -му ребру графа ИС нефтегазодобычи, с учетом его многокомпонентного состава (нефть, газ, вода, механические и другие примеси) описывается набором

переменных x_j^l , характеризующих массовый расход или изменение накопленной массы потока нефтегазовой смеси по компонентам $l = \overline{1, p}$ в технологических линиях или в накопительных элементах, соответствующих j -му ребру графа. Для характеристики этого потока используется также переменная x_j^0 , описывающая массовый расход нефтегазовой смеси в целом или изменение ее накопленной массы в накопительных элементах, соответствующих j -му ребру.

Для совместного представления различных характеристик j -го газожидкостного потока с возможностью их аналитического преобразования в работе применяется аппарат гиперкомплексных чисел (композиционных алгебр) [14]. При этом x_j^0 рассматривается как скалярная (действительная) часть, а x_j^l – как l -я компонента векторной (мнимой) части гиперкомплексного числа [15]

$$x_j = x_j^0 + \sum_{l=1}^p x_j^l e_l = x_j^0 (1 + \sum_{l=1}^p z_j^l e_l), \quad (3)$$

где e_l – l -я мнимая единица гиперкомплексного числа; $\sum_{l=1}^p z_j^l = 1$; $z_j^l = \frac{x_j^l}{x_j^0}$ – доля l -й компоненты x_j^l в j -м газожидкостном потоке.

Составляющие вектора дисбалансов потоков в узлах сети $\text{Dis} = (\text{dis}_i)$, которые определяются в виде

$$\text{Dis} = B[F(Y)] - Q \quad (4)$$

принимают ненулевые значения из-за:

- неадекватности матрицы баланса B структуре реальной ИС;
- неконтролируемых изменений вектора притоков (потерь, утечек) Q ;
- диффузии и химического взаимодействия между компонентами нефтегазовой смеси в технологических линиях и накопительных элементах сети;
- изменения параметров функции связи F ;
- наличия погрешностей измерений V .

Возникновение грубых ошибок ΔDis проявляется в превышении составляющими вектора дисбалансов Dis соответствующих составляющих вектора допустимых значений $\text{Dis}^{\text{доп}}$

$$\Delta \text{Dis} = \text{Dis} - \text{Dis}^{\text{доп}}. \quad (5)$$

3. АДАПТАЦИЯ БАЛАНСНОЙ МОДЕЛИ

Устранение грубых ошибок может быть достигнуто в рамках адаптивной балансной модели с использованием критерия минимума взвешенных квадратов отклонений дисбалансов от допустимых значений

$$J_\Phi = \sum_{h=1}^H (\Delta \text{Dis}^h)^T \Phi_h \overline{\Delta \text{Dis}}^h, \quad (6)$$

учитывающего H гипотез о вероятных причинах возникновения грубых ошибок, т. е. путем определения

$$\begin{aligned} \min_h J_\Phi(\mathbf{F}(Y), \mathbf{Q}) = \\ = \min_h \min_{F^h, Q^h} \left\{ \Delta(B[F^h(Y)] - Q^h)^T \Phi_h \overline{\Delta(B[F^h(Y)] - Q^h)} \right\} \end{aligned} \quad (7)$$

где ΔDis^h – вектор отклонений дисбалансов потоков в узлах ИС от допустимых значений, соответствующий h -й гипотезе возникновения грубых ошибок в узлах ИС, $h = \overline{1, H}$; $\overline{\Delta \text{Dis}}^h$ – сопряженный ему вектор; Φ_h – матрица коэффициентов взвешивания отклонений $\Delta \text{Dis}^h = \Delta(B[F^h(Y)] - Q^h)$ (в начале решения задачи диагностики задается специалистом и определяет метрику пространства дисбалансов); $\mathbf{F}(Y) = (F^h(Y)); \mathbf{Q} = (Q^h)$; $F^h(Y)$ – нелинейная функция связи при h -й гипотезе возникновения грубых ошибок в узлах ИС; Q^h – вектор притоков (утечек, потерь) при h -й гипотезе возникновения грубых ошибок в узлах ИС; T – знак операции транспонирования матрицы.

Источники грубых ошибок, соответствующие возможным решениям задачи диагностики, могут быть найдены с использованием градиентного метода путем решения системы уравнений

$$\nabla J_\Phi(F(Y), Q) = 0. \quad (8)$$

Решения этой системы уравнений могут быть найдены после аппроксимации функции связи F в некотором базисе, с использованием известных алгоритмов обучения, представляемых в виде системы разностных уравнений [16]:

$$Q_t(Y) = Q_{t-1}(Y) - \Gamma_{Q_t} \nabla_Q J_\Phi(F_{t-1}(Y), Q_{t-1}); \quad (9)$$

$$F_t(Y) = F_{t-1}(Y) - \Gamma_{F_t} \nabla_F J_\Phi(F_{t-1}(Y), Q_{t-1}). \quad (10)$$

Данные уравнения позволяют по значениям $F_{t-1}(Y)$ и Q_{t-1} , а также по значениям градиентов $\nabla_F J_\Phi(F_{t-1}(Y), Q_{t-1})$ и $\nabla_Q J_\Phi(F_{t-1}(Y), Q_{t-1})$, рассчитанным на предыдущем интервале оце-

нивания, определить значения $F_i(Y)$ и Q_i на последующем интервале. В этих уравнениях Γ_{Ft} и Γ_{Qt} – матрицы, характеризующие скорости обучения отдельных элементов адаптивной балансной модели ИС.

При аппроксимации функции связи F в нейросетевом вычислительном базисе возможные решения находятся с использованием известных методов обучения нейронных сетей, например, метода обратного распространения ошибки. Процесс обучения заканчивается, если будут достигнуты допустимые значения дисбалансов хотя бы для одной гипотезы h . На основе ранжирования решений по критерию минимума взвешенных квадратов отклонений дисбалансов от допустимых значений, выбираются наиболее достоверные из рассмотренных гипотез возникновения грубых ошибок в узлах ИС, которые подлежат дополнительной проверке путем выполнения работ на объекте.

В рамках каждой h -й гипотезы возникновения грубых ошибок в узлах ИС нефтегазодобычи, на основе результатов проверки правил диагностики, определяются матрицы показателей степени доверия/недоверия к моделям узлов D_h^Q и результатам измерений D_h^F , которые используются для управления скоростями обучения элементов модели:

$$\Gamma_{Ft} = D^F \bar{\Gamma}_{Ft}; \quad (11)$$

$$\Gamma_{Qt} = D^Q \bar{\Gamma}_{Qt}, \quad (12)$$

где $D^F = (D_h^F)$; $D^Q = (D_h^Q)$; $\bar{\Gamma}_{Ft}$, $\bar{\Gamma}_{Qt}$ – матрицы, характеризующие соответственно скорости обучения отдельных элементов адаптивной балансной модели ИС без учета степени доверия/недоверия к результатам измерений и структуре моделей узлов ИС.

4. ПРЕДСТАВЛЕНИЕ МОДЕЛЕЙ В НЕЙРОСЕТЕВОМ БАЗИСЕ

Аппроксимация векторной функции $F(Y)$ в нейросетевом базисе с учетом структуры непрерывных функций многих переменных [17, 18]

$$F(Y) = \sum_{q=1}^m g \left[\sum_{p=1}^n \lambda_{pq} \psi(y_p + \lambda_{0q}) \right], \quad m \geq 2n+1, \quad (13)$$

где g , ψ – непрерывные кусочно-линейные или кусочно-квадратичные функции одного переменного; λ_{pq} – постоянные ($p = 0, n$), позволяет найти нормальное решение системы уравнений балансной модели [19]

$$\text{Dis} = B[F(Y)] - Q = 0. \quad (14)$$

Структура простейшей нейросетевой балансной модели ИС в развернутом виде имеет вид:

$$\text{dis}_i^k = \sum_{j=1}^{n_x} b_{ij}^k \psi \left(\sum_{s=1}^{r_x} \omega_{js}^{kx} a_{js}^{kx} y_s^k \right) - q_i^k, \quad i = \overrightarrow{1, m_x}, \quad (15)$$

где b_{ij}^k – коэффициенты матрицы баланса сети на k -м интервале времени анализа; y_s^k – результат измерения s -й переменной состояния m_x узловых объектов x -го участка ИС с вектором состояния $x = (x_1, x_2, \dots, x_{n_x})$; q_i^k – величина притока (утечки, потерь) в i -м узле ИС нефтегазодобычи; ψ – некоторая известная нелинейная функция; a_{js}^{kx} – коэффициент, характеризующий вес связи между показателями dis_i^k и y_s^k (например, калибровочный коэффициент средства измерения расхода j -го потока ИС);

$$\omega_{js}^{kx} = \begin{cases} 1, & \text{если есть зависимость } \text{dis}_i^k \text{ от } y_s^k; \\ 0, & \text{если нет зависимости.} \end{cases}$$

При диагностике состояния ИС, на основе нейросетевой аппроксимации векторной функции ΔDis , может быть найдена сопровождающая векторная булева функция f , связанная с ΔDis уравнением

$$\text{out} = \psi[\Delta \text{Dis}(\text{in})] = f[\psi(\text{in})], \quad (16)$$

где $\text{out} = (\text{out}_1, \text{out}_2, \dots, \text{out}_m) \in [0,1]^m$ – выходной вектор; $\text{in} = (\text{in}_1, \text{in}_2, \dots, \text{in}_n) \in [0,1]^n$ – входной вектор нейронной сети; ψ – функция активации нейронов сети.

Нейронная сеть диагностической модели реализует векторную булеву функцию, однозначно связанную с сопровождающей булевой функцией f , и представляет ее в виде суперпозиции пороговых функций (если ψ – ступенчатая функция Хевисайда или аппроксимирующая ее функция) или в виде суперпозиции знаковых функций (если ψ – сигнум-функция или аппроксимирующая ее функция) [20].

Наличие связи между векторной функцией ΔDis с векторной булевой функцией f (проверяемыми правилами) позволяет рассматривать ΔDis как R -функцию многих переменных и использовать для определения начальной организации (структуры) нейросетевой диагностической модели методы конструирования R -функций многих переменных в виде суперпо-

зиций кусочно-линейных и кусочно-квадратичных R -функций меньшего числа переменных [21].

Достаточность заданного количества скрытых нейронов в диагностической модели и правильность выбора их возможных реакций определяется с использованием стандартных и модифицированных алгоритмов обучения.

Использование диагностической модели совместно с балансной моделью (в рамках локального нейросетевого анализатора) позволяет минимизировать составляющие вектора дисбалансов Dis , применяя для адаптации нейросетевой балансной модели ИС модифицированный метод обратного распространения ошибки [19, 22]. В рамках этого метода значения скоростей обучения элементов балансной модели определяются, исходя из результатов проверки правил, соответствующих определенной гипотезе о причинах нарушения баланса потоков в узлах ИС [11].

В частности, для управления процессами обучения элементов балансной модели ИС используются результаты проверки следующих правил диагностики:

1) Если имеет место существенный дисбаланс (выше допустимого значения) только в одном i -м внутреннем узле сети, то модель данного узла не достоверна, имеют место неконтролируемые потери (притоки, утечки).

2) Если в двух соседних узлах, связанных j -м ребром, имеют место существенные дисбалансы, равные по модулю, но противоположные по знаку, то результат измерения расхода на j -м ребре не достоверен.

Если распределение долей потоков в граничном узле сети изменяется во времени, то в этом узле имеют место переключения либо возможны метрологические нарушения.

5. СИСТЕМНАЯ ИНТЕГРАЦИЯ НЕЙРОСЕТЕВЫХ АНАЛИЗАТОРОВ

Нейросетевые технологии позволяют параллельно проверять несколько гипотез о причинах нарушения баланса потоков в узлах ИС, генерируя с этой целью нейронные сети локальных анализаторов данных реального времени (множество балансных и диагностических моделей) на основе описания графа ИС нефтегазодобычи, хранимого в базе производственных данных нефтяного промысла. Каждый локальный нейросетевой анализатор настраивается на диагностику и согласование данных реального времени в рамках отдельной гипотезы.

При выдвижении взаимоисключающих гипотез о причинах возникновения грубых ошибок при анализе баланса потоков имеет место соотношение

$$\sum_{h=1}^H \Phi_h = I, \quad (17)$$

где I – единичная матрица.

Если в момент времени t за основу принимается только одна базовая гипотеза $h = h(t)$, то выбор оптимальной функции $\Phi_h(t)$ достигается при динамическом программировании процесса поиска глобального минимума функционала, начиная с момента времени $t_{нач}$,

$$E(t) = \int_{t_{нач}}^t G(t-\tau) J_{\Phi}(\tau) d\tau = \sum_{h=1}^H \int_{t_{нач}}^t G(t-\tau) (\Delta Dis_{\tau}^h)^T \Phi_h(\tau) \overline{\Delta Dis}_{\tau}^h d\tau, \quad (18)$$

где $G(t-\tau)$ – весовая функция памяти принятых решений; ΔDis_{τ}^h – вектор отклонений дисбалансов потоков в узлах ИС от допустимых значений, найденный в момент времени τ в соответствии с h -й гипотезой возникновения грубых ошибок в узлах ИС, $h = \overline{1, H}$.

Оптимизация функционала $E(t)$ по $\Phi_h(t)$ выполняется в процессе многоуровневой системной интеграции (метаинтеграции) локальных нейросетевых анализаторов, обеспечивающих диагностику и согласование данных реального времени в рамках отдельных гипотез о причинах нарушения баланса потоков в узлах ИС.

При реализации процесса метаинтеграции неизвестные параметры модели находятся из условия минимума взвешенных квадратов отклонений значений дисбалансов dis_i^k , рассчитанных в моменты времени t_k по модели, от допустимых $dis_i^{доп}$

$$E_t = \sum_h \sum_k G_{tk} \Phi_{hk} \sum_{i=1}^{m_x} (dis_i^k - dis_i^{доп})^2, \quad (20)$$

где G_{tk} , Φ_{hk} – признаки актуальности замеров, полученных на k -м интервале анализа баланса в рамках h -й гипотезы о причинах возникновения дисбалансов.

Правило обучения, реализуемое при адаптации балансной модели ИС, сводится к модифицированному δ -правилу [12]

$$\omega_{js}^{kx} \Delta a_{js}^{kx} + a_{js}^{kx} \Delta \omega_{js}^{kx} = \alpha_x G_{tk} \Phi_{hk} \delta_j^{kx} y_s^k, \quad (21)$$

где α_x – параметр, задающий предельную скорость обучения, $\delta_j^{kx} = \psi' \sum_{i=1}^{m_x} b_{ij} \Delta dis_i^{kx}$ – ошибка рассогласования в нейросетевой модели для k -го интервала времени; ψ – производная функции ψ ; $\Delta dis_i^{kx} = dis_i^k - dis_i^{доп}$ – величина грубой ошибки в узле ИС.

Определение δ_i^{kx} – рекурсивный процесс, начинающийся с элементов модели, соответствующих корневым узлам участка ИС, распространяющийся к элементам модели, соответствующим промежуточным узлам ИС, и далее к элементам, соответствующим входным или выходным узлам сети с определением коэффициентов a_{jk}^x и контрастирующих их коэффициентов ω_{jk}^x . При достижении рекурсивным процессом элементов модели, соответствующих промежуточным узлам участка ИС, ошибка, полученная по методу обратного распространения, корректируется с учетом величины грубой ошибки в корневых узлах Δdis_i^{kx} .

Процесс обучения с отбором актуальных замеров (задаваемых G_{hk} и Φ_{hk}) и подстройкой коэффициентов нейросетевой модели повторяется вплоть до достижения баланса откорректированных замеров параметров в узлах участка ИС.

В условиях значительной неопределенности состояния узловых технологических объектов и установленного на них оборудования, по значениям коэффициентов a_{jk}^x , полученным в результате обучения, диагностируют их состояние, определяют актуальность гипотез об изменении структуры участка ИС или средств измерения технологических параметров x_j , изменяют начальную организацию нейросетевой модели (коэффициенты ω_{js}^{xk}), с учетом показателей степени доверия/недоверия к структуре моделей узлов ИС (D_i^Q) и к результатам измерения параметров потоков (D_j^F), найденным с помощью диагностической модели, и повторяют процесс обучения.

Процесс метаинтеграции нейросетевых анализаторов является составной частью процесса анализа баланса потоков [13] и решения задач оптимального управления ИС и объектами, подключенными к ним [7]. Полные взвешенные ошибки, оцениваемые при обучении нейросетевых моделей, наряду с технико-экономическими

показателями могут рассматриваться как показатели функционирования агрегированных структур (подкомплексов) автоматизированного технологического комплекса нефтегазодобычи и использоваться в процессе метаинтеграции локальных анализаторов данных реального времени путем согласованного обучения их нейронных сетей.

6. РЕАЛИЗАЦИЯ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ

Программный комплекс (ОАО «Нефтеавтоматика») [14], реализующий нейросетевые модели ИС, включает в себя:

- базу данных реального времени;
- базу производственных данных;
- модуль расчета дисбалансов;
- модуль диагностики;
- модуль адаптации.

База данных реального времени необходима для хранения результатов прямых измерений и формирования оценок параметров газо-жидкостных потоков ИС нефтегазодобычи.

База производственных данных используется для хранения истории изменений структуры ИС и ее графовых моделей, а также типовых карточек, отражающих прецеденты выявления грубых ошибок в определении распределения потоков ИС нефтегазодобычи.

Модуль расчета дисбалансов по каждой h -гипотезе возникновения грубых ошибок в узлах ИС обеспечивает определение вектора дисбалансов Dis^h .

Модуль диагностики определяет показатели степени доверия/недоверия к структуре моделей узлов D_h^Q и измеренным значениям параметров многокомпонентных потоков ИС нефтегазодобычи D_h^F , найденным на основе правил диагностики, с учетом информации, вводимой пользователем в виде матриц коэффициентов взвешивания Φ_h , $h=1, \overline{H}$, используемых при отборе гипотез возникновения грубых ошибок в узлах ИС.

Модуль адаптации регулирует процессы обучения и осуществляет метаинтеграцию нейронных сетей локальных анализаторов, обеспечивая определение параметров модели каждого узла ИС (калибровочных функций измерительных приборов, параметров моделей технологических объектов ИС и пр.) на основе данных реального времени в рамках H гипотез возникновения грубых ошибок в узлах ИС.

Модули программного комплекса диагностики состояния ИС нефтегазодобычи образуют интеллектуальную нейросистему [7].

Вычислительным ядром (основой) интеллектуальной нейросистемы контроля и диагностики является модуль расчета дисбалансов, реализующий балансную модель ИС в виде множества нейронных сетей. Отдельная h -я нейронная сеть этой нейросетевой модели обеспечивает моделирование ИС с матрицей баланса B , функцией связи F^h и вектором притоков Q^h , а также расчет значений вектора дисбаланса Dis^h в соответствии с h -й гипотезой возникновения грубых ошибок в узлах ИС. Блок управления (интеллектуальную надстройку) нейросистемы образуют модули диагностики и адаптации.

Архитектура интеллектуальной нейросистемы контроля и диагностики состояния ИС нефтегазодобычи приведена на рис. 1.

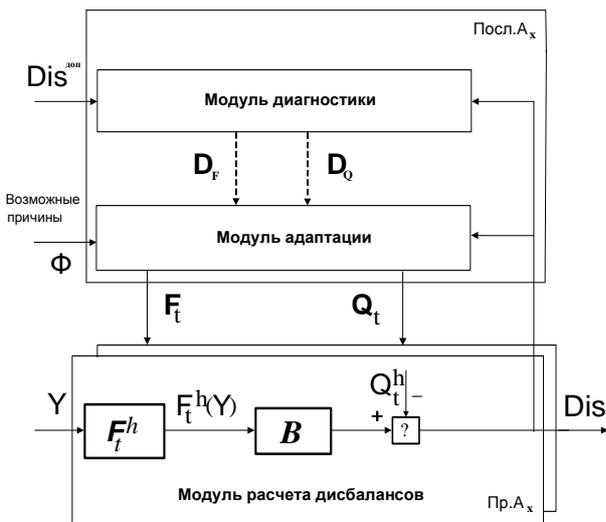


Рис. 1. Архитектура нейросистемы контроля и диагностики

Модуль диагностики обеспечивает определение совокупности показателей степени доверия/недоверия к структуре моделей узлов D^Q и измеренным значениям параметров многокомпонентных потоков ИС нефтегазодобычи D^F , найденным на основе правил диагностики, а также с учетом информации, вводимой пользователем для определения совокупности матриц коэффициентов взвешивания Φ .

Процесс обучения нейросетевой адаптивной балансной модели ИС, с определением параметров моделей отдельных узлов ИС на последующем интервале оценивания (калибровочных

функций измерительных приборов, параметров технологических линий $F_t(Y)$ и притоков/утечек в узлах Q_t), реализуется модулем адаптации на основе значений дисбалансов Dis и значений $F_{t-1}(Y)$ и Q_{t-1} , полученных на предыдущем интервале оценивания. Нейросетевая адаптивная балансная модель инженерной сети генерируется программным комплексом диагностики на основе описания графа инженерной сети, хранимого в базе производственных данных. Локальные нейросетевые анализаторы реализуются в виде сервисов и обеспечивают выполнение вычислений при согласовании данных и определении причин нарушения балансов материальных и энергетических потоков в ИС [23].

Разработана методика анализа баланса потоков в ИС нефтегазодобычи на основе балансных моделей инженерных сетей, а также ряд нейросетевых программных модулей, которые используются в составе интегрированной автоматизированной системы управления технологическими процессами нефтепромысла [23, 24].

7. ПРИМЕР ПОСТРОЕНИЯ МОДЕЛИ

На рис. 2 приведена графовая модель типового участка ИС нефтегазодобычи.

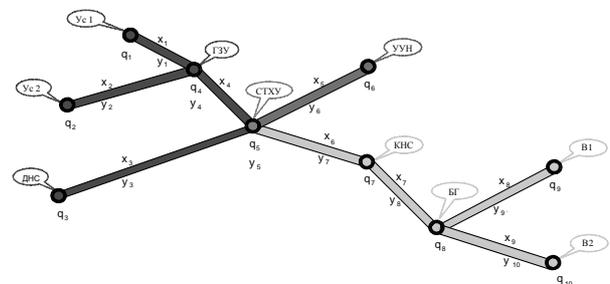


Рис. 2. Графовая модель участка ИС нефтедобычи

Термохимическая установка для подготовки сернистой нефти (СТХУ) формирует на выходе поток нефти, направляемый на узел учета нефти (УУН), и поток пластовой воды, направляемый на кустовую насосную станцию (КНС), блочную гребенку (БГ) и водоводы (В1 и В2), к которым подключаются нагнетательные скважины. Нефтяная эмульсия поступает на вход СТХУ с отводов дожимных насосных станций (ДНС) и близлежащей групповой замерной установки (ГЗУ). К усам (Ус1, Ус2) ГЗУ подключены выкидные линии нефтяных скважин, расходные параметры газожидкостных потоков

которых измеряются последовательно во времени в измерительной линии ГЗУ.

В графовой модели участка ИС выделены два внутренних узла. Узел, соответствующий ГЗУ, связан с периферийными узлами Ус 1 и Ус 2. Узел, соответствующий СТХУ, связан с узлами УУН и КНС. Каждому i -у потоку в модели приписан параметр расхода x_i и результат его измерения y_i (для x_4 отсутствует), а каждому j -у узлу – величина притока (утечки) q_j и результат изменения давления y_j (если он имеется – y_4 и y_5 для узлов ГЗУ и СТХУ).

Для реализации правил диагностики состояния ИС нефтегазодобычи (см. п. 4) путем контроля баланса в узлах ИС в модуле диагностики используются нейронные сети, реализующие логические функции над признаками наличия больших ошибок в расчетах баланса потоков.

В соответствии с правилом диагностики 2, для внутреннего i -го узла ИС нефтегазодобычи показатель степени доверия/недоверия к модели узла D_i^o высокий, если имеется существенный дисбаланс только в этом узле, а в смежных узлах нет. Это правило диагностики может быть проверено с использованием AND-подобной логической функции для любого из внутренних узлов участка ИС.

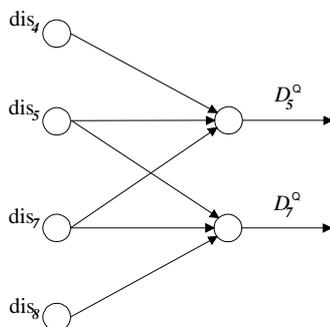


Рис. 3. Нейросетевая диагностическая модель, реализующая проверку правила 1

Нейронная сеть, представленная на рис. 3, реализует правило 1 для определения показателей степени доверия/недоверия к моделям узлов 5 и 7. Она состоит из 4 входных и 2 выходных нейронов и не имеет скрытых нейронов. С помощью данной нейронной сети определяются показатели D_5^o и D_7^o , указывающие на возможное наличие неучтенных утечек в узлах 5 и 7.

В соответствии с правилом диагностики 2, показатель степени доверия/недоверия к результату измерения расхода на j -м ребре высокий,

если в двух соседних узлах, связанных j -м ребром, имеют место существенные дисбалансы, равные по модулю, но противоположные по знаку. Это правило диагностики может быть проверено для каждого потока, общего для двух смежных узлов участка ИС, с помощью нейронной сети, реализующей XOR-подобную логическую функцию с использованием двух скрытых нейронов.

В рассматриваемом примере нейронной сети, реализующей проверку правила 2 (рис. 4), определяются показатели степени доверия/недоверия D_4^F , D_6^F и D_7^F для измерений, выполняемых на ребрах 4, 6 и 7.

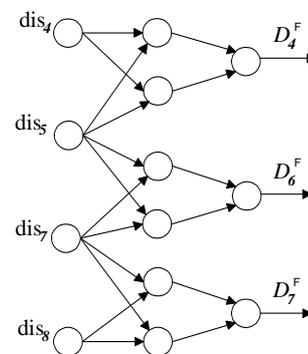


Рис. 4. Нейросетевая диагностическая модель, реализующая проверку правила 2

На рис. 5 приведена нейросетевая адаптивная балансная модель участка ИС, предназначенная для анализа баланса потоков по массовым расходным параметрам нефтегазовой смеси в целом и по расходным параметрам отдельных компонент потоков (по нефти и сточной воде). В составе адаптивной балансной модели, кроме собственно балансной модели, имеются две диагностические модели, реализующие проверку правил 1 и 2, которые образуют вместе с балансной моделью два локальных анализатора данных реального времени интеллектуальной нейросистемы. Формируемые с их помощью показатели степени доверия/недоверия D_5^o , D_7^o и D_4^F , D_6^F , D_7^F соответственно используются для управления контуром обучения нейросетевой балансной модели на альтернативной основе (с учетом матрицы Φ).

В данной модели верхние индексы параметров, определяемых модулем расчета дисбалансов, имеют следующие значения: 0 –

нефтегазовая смесь в целом; 1 – нефть; 2 – сточная вода.

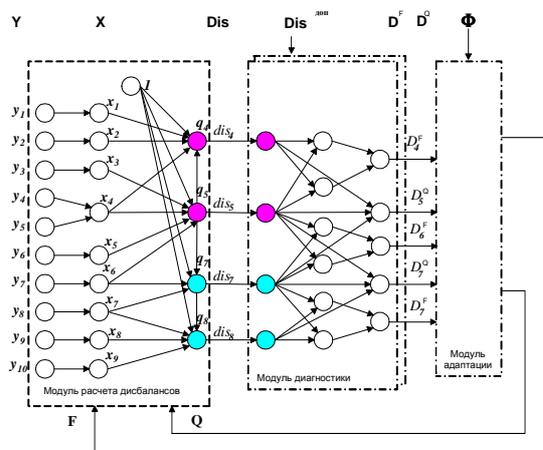


Рис. 5. Нейросетевая адаптивная балансная модель для анализа баланса потоков участка ИС нефтегазодобычи

ВЫВОДЫ

1. В работе с учетом возможностей современных нейросетевых технологий определена архитектура интеллектуальной нейросистемы контроля и диагностики состояния ИС нефтегазодобычи. Даны рекомендации по выбору начальной организации (структуры) нейронных сетей локальных анализаторов данных реального времени интеллектуальной нейросистемы и их последующей системной интеграции, путем согласования процессов обучения нейронных сетей, обеспечивающих диагностику состояния ИС нефтегазодобычи, идентификацию параметров адаптивной балансной модели и согласование результатов измерения параметров потоков ИС.

2. Решена задача генерирования и представления в базе данных программного комплекса нефтяного промысла нейронных сетей анализаторов данных реального времени, на основе описания оргграфа ИС, хранящегося в этой базе данных.

3. Разработана методика анализа баланса потоков в ИС нефтегазодобычи на основе балансных моделей инженерных сетей, а также ряд нейросетевых программных модулей, которые используются в составе интегрированной автоматизированной системы управления технологическими процессами нефтепромысла.

СПИСОК ЛИТЕРАТУРЫ

1. Евдокимов, А. Г. Оптимальные задачи на инженерных сетях / А. Г. Евдокимов. Харьков : Вища школа, 1976. 153 с.

2. Меренков, А. П. Теория гидравлических цепей / А. П. Меренков, В. Я. Хасилев. М. : Наука, 1985. 280 с.

3. Математическое моделирование и оптимизация систем тепло-, водо-, нефте- и газоснабжения / А. П. Меренков, Е. В. Сеннова, С. В. Сумароков и др. Новосибирск : Наука, СИФ РАН, 1992. 407 с.

4. Гидродинамические цепи. Развитие теории и приложения / Н. Н. Новицкий, Е. В. Сеннова, М. Г. Сухарев и др. Новосибирск : Наука. СИФ РАН, 2000. 375 с.

5. Soudek, A. Improve information quality through data reconciliation [Электронный ресурс] (<http://www.osisoft.com>).

6. Chow, M.-Y. Enhancement of the performance of a neural network based motor fault detector using graphical data analysis techniques / B. Li, G. Goddu, M.-Y. Chow // Proceeding of 1998 IEEE World congress on computational intelligence. Anchorage : AL, 1998. P. 63–68.

7. Зозуля, Ю. И. Интеллектуальные нейросистемы / Ю. И. Зозуля. М. : Радиотехника, 2003. 143 с.

8. Narasimhan, S. Application of neural networks for gross error detection / G. Gupta, S. Narasimhan // Ind. Eng. Chem. Res., 1993. V. 32. P. 1651–1657.

9. Идентификация моделей гидравлики / Г. Д. Бабе, Э. В. Бондарев, А. Ф. Воеводин, М. А. Каниболотский. Новосибирск : Наука, 1980. 161 с.

10. Зозуля, Ю. И. Использование теоремы Колмогорова при преобразовании структур в задачах нейросетевого управления / Ю. И. Зозуля, Г. Г. Губайдуллин, Э. С. Арутюнян // Нейрокомпьютеры: разработка и применение. 2000. № 1. С. 36–39.

11. Зозуля, Ю. И. Нейросетевые технологии в решении задач анализа и диагностики состояния инженерных сетей / Ю. И. Зозуля, Д. Ф. Назипов, Р. Р. Ахметзянов, А. А. Жильцов // Автоматизация телемеханизация и связь в нефтяной промышленности, 2007. № 4. С. 25–30.

12. Зозуля, Ю. И. Метаинтеграция нейронных сетей в интеллектуальных автоматизированных системах реального времени / Ю. И. Зозуля, Ю. С. Кабальнов. Уфа : УГАТУ, 2008. 229 с.

13. Анализ баланса потоков жидкости в инженерных сетях нефтегазодобывающего предприятия: Методические материалы / М. А. Слепян, Ю. И. Зозуля, А. К. Муравский, С. И. Братцев, Н. М. Сибгатуллин. Уфа : Монография, 2002. 120 с.

14. Гиперкомплексные числа / И. Л. Кантор, А. С. Солодовников. М. : Наука, 1973. 156 с.

15. Зозуля, Ю. И. Адаптивная балансная модель инженерной сети нефтегазодобычи / А. А. Жильцов, Ю. И. Зозуля // Автоматизация, телемеханизация и связь в нефтяной промышленности. 2006. № 3. С. 36–39.

16. **Цыпкин, Я. З.** Основы теории обучающихся систем / Я. З. Цыпкин. М. : Наука, 1970. 252 с.

17. **Колмогоров, А. Н.** Представление непрерывных функций многих переменных суперпозицией функций одной переменной и сложением / А. Н. Колмогоров // ДАН СССР. 1958. Т. 114, № 5. С. 953–956.

18. **Sprecher, D. A.** On the structure of continuous functions of several variables / D. A. Sprecher // Transactions of the American Mathematical Society, 1965. V. 115. P. 340–355.

19. **Зозуля, Ю. И.** Реализация адаптивной балансной модели инженерной сети в нейросетевом базисе / Ю. И. Зозуля // Сб. трудов международной конференции «Актуальные проблемы прикладной математики и механики». Харьков: ИПМАШ, 2006. С. 53.

20. **Каянелло, Э. Р.** Точное решение нелинейных уравнений, описывающих нейронную сеть / Э. Р. Каянелло // Исследования по теории структур. М. : Наука, 1988. С. 193–203.

ОБ АВТОРАХ



Зозуля Юрий Иванович, гл. спец. АО «Нефтеавтоматика», доц. каф. информатики. Дипл. инж.-элек. ЭВМ (ХИРЭ, 1970). Канд. техн. наук по техн. киберн. Иссл. нейросетевых технологий в обл. автоматизации нефтегазодобычи.



Жильцов Александр Адольфович, гл. метрол. – нач. отд. метрол. и учета нефти АО «Татнефть». Дипл. инж. по авт. (АГНИ, 1990). Готовит дис. по интелл. анализу баланса потоков в инж. сетях нефтегазодобычи.



Кабальнов Юрий Степанович, проф., зав. каф. информатики. Дипл. инж. электр. техн. (УАИ, 1971). Д-р. техн. наук по управлению в техн. системах. Иссл. в обл. адаптивного и интелл. управления сложными техн. системами.