

О. В. Серая, к. т. н., доц.; Т. И. Каткова к. п. н, доц.

## НЕЙРОСЕТЕВАЯ ПРОДУКЦИОННАЯ ЭКСПЕРТНАЯ СИСТЕМА ДИАГНОСТИКИ СОСТОЯНИЯ

*Предложена экспертная система с нейросетевым механизмом логического вывода. Разработана процедура прогнозирования состояния диагностируемого объекта таким механизмом.*

*Ключевые слова:* экспертная система, продукционные правила, нейросетевые структуры, механизм логического вывода, прогнозирование состояния объектов.

### Введение

Современные информационные технологии диагностики состояния объектов эффективно используют специфические системы искусственного интеллекта – экспертные системы (ЭС). Такие системы организованы таким образом, чтобы с использованием результатов измерения набора контролируемых параметров  $x_1, x_2, \dots, x_n$  объекта диагностировать его состояние. Принципы функционирования и структура диагностических экспертных систем существенно зависят от типа механизма логического вывода (МЛВ). На практике используются два конструктивно разных подхода к построению МЛВ: продукционный и байесов. Нашедший более широкое применение, продукционный подход основан на системе так называемых продукционных правил, построенных следующим образом [1]:

если  $x_1$  есть  $A_1$ ,  $x_2$  есть  $A_2, \dots$ ,  $x_n$  есть  $A_n$ , то с вероятностью  $p(A_1, A_2, \dots, A_n)$   
объект находится в состоянии  $H(A_1, A_2, \dots, A_n)$ .

Продукционные системы удобны для практического применения и просты в реализации. Однако серьезный их недостаток состоит в конструктивно заложенной зависимости эффективности системы диагностики от размерности набора контролируемых параметров. Дело в том, что система диагностики должна обладать полнотой, то есть необходимо, чтобы для каждого возможного варианта значений набора контролируемых параметров существовало соответствующее продукционное правило. Это означает, что если каждый параметр может принять одно из  $m$  возможных значений, то общее число продукционных правил будет равно  $N = m^n$  и быстро растет с увеличением  $m$  и  $n$ .

Байесов механизм логического вывода [2] практически снимает проблему размерности. Однако практические возможности таких систем ограничиваются необходимостью статистической независимости контролируемых параметров. Попытка обойти эту трудность предпринята в [3]. При этом, зависимые параметры объединяются в группы. Далее параметры, входящие в одну группу, обрабатываются с использованием продукционных правил. Получающиеся результаты для разных групп уже практически не зависимы и используются в байесовой технологии. Такая ЭС с комбинированным МЛВ позволяет решать задачи диагностики для высокой размерности набора контролируемых параметров и их возможной коррелированности. Вместе с тем, ей присущ общий принципиальный недостаток любых ЭС – дискретный характер контролируемых параметров. И в продукционной, и в байесовой системах каждый из параметров – это либо симптом с булевым характером проявления, либо, если это непрерывный параметр, диапазон возможных его значений должен быть разбит на поддиапазоны, то есть дискретизован. Это обстоятельство при практической разработке ЭС приводит к ряду проблем. Во-первых, если число поддиапазонов велико, выбор рационального числа поддиапазонов должен быть результатом нетривиального компромисса между сложностью МЛВ и точностью оценивания состояния в противном случае. Во-вторых, границы поддиапазонов трудно объяснимы

теоретически. В-третьих, само существование границ поддиапазонов может привести к противоестественной ситуации, когда двум близким по численным значениям наборам параметров будут соответствовать разные диагнозы.

Все эти проблемы могут быть устранены, если МЛВ будет конструктивно приспособлен к обработке непрерывных по своей природе параметров. Такой МЛВ может быть реализован с использованием искусственных нейронных сетей (ИНС). Сформулируем задачу разработки ЭС с нейросетевым механизмом логического вывода, предназначенную для оценки и прогнозирования состояния диагностируемого объекта.

### Постановка задачи

Как известно, ИНС осуществляет отображение точек из многомерного пространства наблюдений  $X$  размерности  $n$  в точки многомерного пространства  $Y$  решений другой, в общем случае, размерности  $H$ . При этом правильное отображение точек из  $X$  в  $Y$  обеспечивается специальным образом организованной процедурой обучения сети. Пусть проводится серия измерений контролируемых параметров объекта, в результате которых получим наборы  $X_1 = (x_{11}, x_{12}, \dots, x_{1j}, \dots, x_{1n})$ ,  $X_2 = (x_{21}, x_{22}, \dots, x_{2j}, \dots, x_{2n})$ , ...,  $X_l = (x_{l1}, x_{l2}, \dots, x_{lj}, \dots, x_{ln})$ , ...,  $X_L = (x_{L1}, x_{L2}, \dots, x_{Lj}, \dots, x_{Ln})$ . В процессе обучения сети эти наборы предъявляются  $Q$  экспертам, которые для каждого набора  $X_l, l = 1, 2, \dots, L$ , задают распределение вероятностей  $P_{lq} = (p_{lq1}, p_{lq2}, \dots, p_{lqh}, \dots, p_{lqH})$ ,  $l = 1, 2, \dots, L$ ,  $q = 1, 2, \dots, Q$ , состояний  $h = 1, 2, \dots, H$  объекта. Элементарная статистическая обработка результатов экспертного оценивания ставит в соответствие каждому набору измерений  $X_l$  распределение средних значений вероятностей состояний (диапазонов)  $\hat{P}_l$  и набор дисперсий вероятностей  $\hat{\sigma}_l^2$ . Полученные данные используются для обучения ИНС, после которого нейронная сеть для каждого нового вектора измерений контролируемых параметров формирует соответствующие векторы  $P(X)$  и  $\sigma^2(X)$ . Проблемным остается вопрос о возможности использования ИНС для прогнозирования состояния объекта. Рассмотрим две альтернативные методики решения этой задачи.

### Основные результаты

А. Микроподход. Поскольку обученная ИНС для каждого вектора наблюдений набора контролируемых параметров определяет соответствующее ему распределение вероятностей диагнозов, то решение задачи прогнозирования состояния объекта может быть получено путем прогнозирования вектора наблюдений.

Используем наборы  $X_1, X_2, \dots, X_n$  для формирования матрицы наблюдений:

$$X = \begin{pmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \dots & \dots & \dots & \dots \\ x_{L1} & x_{L2} & \dots & x_{Ln} \end{pmatrix}.$$

Столбцы этой матрицы соответствуют отсчетам каждого из контролируемых параметров для моментов времени  $t_1, t_2, \dots, t_L$ . Введем модель эволюции параметров во времени:

$$x_j(t) = \sum_{i=0}^d c_{ij} t^i, \quad j = 1, 2, \dots, n. \quad (1)$$

Расчет параметров  $(c_{ij})$  модели (1) проведем по методу наименьших квадратов, используя матрицу

$$H = \begin{pmatrix} 1 & t_1 & \dots & t_1^d \\ 1 & t_2 & \dots & t_2^d \\ \dots & \dots & \dots & \dots \\ 1 & t_L & \dots & t_L^d \end{pmatrix}$$

и векторы

$$c_1 = \begin{pmatrix} c_{01} \\ c_{11} \\ \dots \\ c_{d1} \end{pmatrix}, c_2 = \begin{pmatrix} c_{02} \\ c_{12} \\ \dots \\ c_{d2} \end{pmatrix}, \dots, c_n = \begin{pmatrix} c_{0n} \\ c_{1n} \\ \dots \\ c_{dn} \end{pmatrix}, X^{(1)} = \begin{pmatrix} x_{11} \\ x_{21} \\ \dots \\ c_{L1} \end{pmatrix}, X^{(2)} = \begin{pmatrix} x_{12} \\ x_{22} \\ \dots \\ c_{L2} \end{pmatrix}, \dots, X^{(n)} = \begin{pmatrix} x_{1n} \\ x_{2n} \\ \dots \\ c_{Ln} \end{pmatrix}.$$

Теперь набор векторов оценок параметров уравнений регрессии (1) найдем, минимизируя функционалы:

$$\begin{aligned} J_1(c_1) &= (Hc_1 - X^{(1)})^T (Hc_1 - X^{(1)}), \\ J_2(c_2) &= (Hc_2 - X^{(2)})^T (Hc_2 - X^{(2)}), \\ &\dots \\ J_n(c_n) &= (Hc_n - X^{(n)})^T (Hc_n - X^{(n)}). \end{aligned}$$

При этом оптимальные в смысле метода наименьших квадратов векторы регрессионных коэффициентов получим по формулам:

$$\hat{c}_j = (H^T H)^{-1} H^T X^{(j)}, \quad j = 1, 2, \dots, n. \tag{2}$$

Подстановка (2) в (1) задает совокупность аналитических описаний поведения контролируемых параметров во времени, обеспечивающих возможность расчета их значений на момент  $t_{np}$  прогноза:

$$x_j(t_{np}) = \sum_{i=0}^d \hat{c}_{ij} t_{np}^i, \quad j = 1, 2, \dots, n.$$

Полученному при этом набору значений параметров

$$X(t_{np}) = (x_1(t_{np}), x_2(t_{np}), \dots, x_n(t_{np}))$$

обучение ИНС поставит в соответствие распределение вероятностей состояний объекта на момент прогноза.

Б. Макроподход. Последовательно подавая на вход ИНС наборы наблюдений  $x_1, x_2, \dots, x_n$ , получим соответствующие им распределения вероятностей диагнозов:

$$\begin{aligned} P_1(t_1) &= (p_{11}, p_{12}, \dots, p_{1H}), \\ P_2(t_2) &= (p_{21}, p_{22}, \dots, p_{2H}), \\ &\dots \\ P_L(t_L) &= (p_{L1}, p_{L2}, \dots, p_{LH}). \end{aligned} \tag{3}$$

Закон изменения вероятностей для каждого, например,  $h$ -го,  $h = 1, 2, \dots, H$ , из диапазонов описывается соответствующей функцией времени  $P_h(t)$ , которая может быть представлена разложением в ряд по некоторой совокупности базисных функций в соответствии с моделью:

$$P_h(t) = \sum_{i=0}^m a_{ih} \varphi_i(t), \quad h = 1, 2, \dots, H, \tag{4}$$

где  $\varphi_0(t), \varphi_1(t), \dots, \varphi_m(t)$  – набор базисных функций.

Следует отметить, что шаблонное независимое оценивание параметров моделей (4) для каждого диагноза в отдельности невозможно, так как при этом не будет учтено условие

нормировки: сумма вероятностей диагнозов на любой момент времени должна быть равна единице.

В связи с этим рассмотрим другой подход.

Простая технология использования набора распределений вероятностей (3), соответствующих моментам наблюдений  $t_1, t_2, \dots, t_L$ , для расчета распределения на момент прогноза состоит в следующем.

Аппроксимируем каждое из распределений (3) непрерывной кривой  $f(t_i, \theta_1(t_i), \theta_2(t_i), \dots, \theta_q(t_i))$ , имеющей смысл плотности распределения вероятностей диагнозов и зависящей от  $q$  параметров. Теперь для каждого из наборов  $(\theta_1(t_1), \theta_1(t_2), \dots, \theta_1(t_L))$ ,  $(\theta_2(t_1), \theta_2(t_2), \dots, \theta_2(t_L))$ ,  $\dots$ ,  $(\theta_q(t_1), \theta_q(t_2), \dots, \theta_q(t_L))$  построим аналитическое продолжение и вычислим совокупность параметров  $\theta_1(t_{np}), \theta_2(t_{np}), \dots, \theta_q(t_{np})$ , которая однозначно задает искомое распределение вероятностей диагнозов на момент  $t_{np}$  прогноза. К сожалению, эта элементарная по идее процедура может оказаться чрезмерно трудоемкой, так как характер каждого из распределений (3) может быть настолько сложным, что потребует для адекватной его аппроксимации неприемлемо большое число параметров  $q$ , либо будет недопустимо грубым.

Альтернатива состоит в использовании для описания распределений (3) эмпирических законов распределения, принципиальное свойство которых – монотонное неубывание. Для оценивания эмпирического закона распределения может быть использован функционал

$$g(t) = \frac{1}{2} + \frac{1}{2}th(y(t)), \quad (5)$$

в котором  $y(t)$  обеспечивает адаптацию эмпирического закона  $g(t)$  к реальным данным. В [4] показано, что достаточно хорошую по качеству аппроксимацию реальных эмпирических законов распределения обеспечивает описание  $y(t)$  в виде квадратичного полинома. Общая схема прогнозирования такова. Совокупность распределений  $P_1(t_1), P_2(t_2), \dots, P_L(t_L)$  преобразуются в эмпирические интегральные законы:

$$R_l = (R_{l1}, R_{l2}, \dots, l), R_2 = (R_{21}, R_{22}, \dots, l), \dots, R_L = (R_{L1}, R_{L2}, \dots, l),$$

где

$$R_{lh} = \sum_{h=1}^H P_{lh}, \quad l = 1, 2, \dots, L.$$

Далее каждый из полученных интегральных законов независимо аппроксимируется с использованием функционала (5), представленного в форме:

$$g_l(h) = \frac{1}{2} + \frac{1}{2}th(a_{0l} + a_{1l}h + a_{2l}h^2), \quad l = 1, 2, \dots, L, \quad h = 1, 2, \dots, H. \quad (6)$$

Показатель качества аппроксимации имеет вид:

$$W_l = \sum_{h=1}^H (R_{lh} - g_l(h))^2.$$

Минимизация (7) осуществляется методом наименьших квадратов. В результате получается совокупность наборов  $\{(a_{01}, a_{11}, a_{21}), (a_{02}, a_{12}, a_{22}), \dots, (a_{0L}, a_{1L}, a_{2L})\}$ . Эти наборы используются для получения полиномиальных функций  $a_0(t), a_1(t), a_2(t)$ , обеспечивающих возможность описания аппроксимации (6) для любого момента времени.

Рассмотрим эту методику подробнее. Для описания функций  $a_0(t), a_1(t), a_2(t)$  используем систему функций  $\psi_1(t_1), \psi_2(t_1), \dots, \psi_d(t_1)$ , ортогональных на совокупности равноотстоящих точек  $t_1, t_2, \dots, t_L$  так, чтобы

$$\sum_{l=1}^L \psi_{k_1}(t_l) \psi_{k_2}(t_l) = \begin{cases} L, & k_1 = k_2, \\ 0, & k_1 \neq k_2. \end{cases} \quad (8)$$

Опишем  $a_0(t), a_1(t), a_2(t)$  следующим образом:

$$\begin{aligned} a_0(t) &= \sum_{i=0}^d b_{0i} \psi_i(t), \\ a_1(t) &= \sum_{i=0}^d b_{1i} \psi_i(t), \\ a_2(t) &= \sum_{i=0}^d b_{2i} \psi_i(t). \end{aligned} \quad (9)$$

С использованием результатов аппроксимации (6) – (7) введем наборы значений этих функций на совокупности аргументов  $t_1, t_2, \dots, t_L$ :

$$A_0 = \begin{pmatrix} a_{01} \\ a_{02} \\ \dots \\ a_{0L} \end{pmatrix}, \quad A_1 = \begin{pmatrix} a_{11} \\ a_{12} \\ \dots \\ a_{1L} \end{pmatrix}, \quad A_2 = \begin{pmatrix} a_{21} \\ a_{22} \\ \dots \\ a_{2L} \end{pmatrix}.$$

Теперь введем матрицу

$$\psi = \begin{pmatrix} \psi_0(t_1) & \psi_1(t_1) & \dots & \psi_d(t_1) \\ \psi_0(t_2) & \psi_1(t_2) & \dots & \psi_d(t_2) \\ \dots & \dots & \dots & \dots \\ \psi_0(t_L) & \psi_1(t_L) & \dots & \psi_d(t_L) \end{pmatrix}$$

и векторы

$$B_0^T = (b_{00} \quad b_{01} \quad \dots \quad b_{0d}), \quad B_1^T = (b_{10} \quad b_{11} \quad \dots \quad b_{1d}), \quad B_2^T = (b_{20} \quad b_{21} \quad \dots \quad b_{2d}).$$

Искомые векторы  $B_0, B_1, B_2$  найдем минимизируя функционалы:

$$M_k = (\psi B_k - A_k)^T (\psi B_k - A_k), \quad k = 1, 2, 3.$$

При этом

$$\hat{B}_k = (\psi^T \psi)^{-1} \psi^T A_k.$$

Поскольку, в силу (8)  $(\psi^T \psi)^{-1} = \frac{1}{L} I$ , где  $I$  – единичная матрица, то

$$\hat{B}_k = \frac{1}{L} \begin{pmatrix} \sum_{l=1}^L a_{kl} \psi_0(t_l) \\ \sum_{l=1}^L a_{kl} \psi_1(t_l) \\ \dots \\ \sum_{l=1}^L a_{kl} \psi_d(t_l) \end{pmatrix}, \quad k = 1, 2, 3. \quad (10)$$

Подставляя (10) в (9), вычислим значения параметров  $a_{0l}, a_{1l}, a_{2l}$  для любого  $t$ . Теперь, используя (6), рассчитаем эмпирический закон распределения вероятностей диагнозов на момент  $t_{np}$  прогноза.

Таким образом, задача прогнозирования вектора вероятностей состояний системы решена.

### Выводы

В статье предложена методика использования ЭС с нейросетевым механизмом

логического вывода для прогнозирования состояния диагностируемого объекта. Рассмотрены два альтернативных подхода к решению задачи. Один из них основан на прогнозировании поведения контролируемых параметров. Второй подход реализует предложенную методику непосредственного прогнозирования распределений вероятностей состояний отказа.

#### СПИСОК ЛИТЕРАТУРЫ

1. Уотермен Д. Руководство по экспертным системам: Пер. с англ. – М.: МИР, 1989. – 388 с.
2. Нейлор К. Как построить свою экспертную систему: Пер с англ. – М.: Энергоиздат, 1991. – 286 с.
3. Миненкова З. Е. Комбинированный механизм логического вывода байесовой диагностической экспертной системы // Вестник ХПИ. – 2003. – № 6. – С. 69-74.
4. Серая О. В. Модели и информационные технологии оценки и прогнозирования состояния многомерных динамических объектов в условиях нечетких входных данных: Дис. канд. техн. наук: 05.13.06. – Х., 2001. – 251 с..

***Серая Оксана Владимировна*** – к. т. н., доцент кафедры экономической кибернетики и маркетингового менеджмента, тел. (8057)-707-66-28.

Национальный технический университет "Харьковский политехнический институт".

***Каткова Татьяна Игоревна*** – к. п. н., доцент, заведующий кафедры математики и математических методов, тел. (06153)-71971.

Бердянский университет менеджмента и бизнеса.