

УДК 004.93

С. А. Субботин

Запорожский национальный технический университет
ул. Жуковского, 64, 69063 Запорожье, Украина

Синтез диагностических моделей на основе нейро-нечетких сетей с высокими обобщающими свойствами

Разработан метод синтеза диагностических моделей на основе нейро-нечетких сетей, обладающих высокими обобщающими свойствами, который выделяет и редуцирует нечеткие термы, формирует и обобщает набор продукционных правил, на основе которого в неитеративном режиме синтезирует нейро-нечеткую сеть, что позволяет повысить обобщающие свойства, а также упростить структуру диагностических моделей.

Ключевые слова: *нейро-нечеткая сеть, техническое диагностирование, обобщение.*

Введение

Для решения задачи автоматизации процесса технического диагностирования промышленных изделий необходимо обладать диагностической моделью (ДМ), позволяющей определять класс изделия (значение выходного признака) по набору значений описательных (входных) признаков [1]. Причем построение такой модели на практике затруднено отсутствием или неполнотой экспертных знаний и, как правило, предполагает синтез ДМ по набору прецедентов — наблюдений с известными значениями входных и выходных признаков.

В настоящее время наиболее удобным базисом для построения ДМ по прецедентам являются нейро-нечеткие сети (ННС), которые подобно нейронным сетям способны к машинному обучению по прецедентам, но в отличие от них являются интерпретабельными, поскольку позволяют проследить и объяснить ход принятия решений, а также позволяют извлекать знания из ДМ в виде продукционных правил [2].

Однако известные методы синтеза ННС [2–4] требуют либо участия пользователя в процессе построения ДМ, который формирует знания в виде продукционных правил (это снижает уровни автоматизации процесса построения ДМ и объективности получаемой ДМ), либо характеризуются крайне низким уровнем обобщения прецедентов вследствие отображения всей выборки в структуру и параметры модели.

© С. А. Субботин

Поэтому актуальной задачей является создание методов, позволяющих синтезировать ДМ на основе ННС в автоматическом режиме, которые обладают выскими обобщающими свойствами и интерпретабельностью.

Постановка задачи

Пусть мы имеем обучающую выборку $\langle x, y \rangle$ — набор S прецедентов о зависимости $y(x)$, заданных человеком-экспертом, $x = \{x^s\}$, $y = \{y^s\}$, $s = 1, 2, \dots, S$, характеризующихся набором N входных признаков $\{x_j\}$, $j = 1, 2, \dots, N$, где j — номер признака, и выходным признаком y . Каждый s -й прецедент представим как $\langle x^s, y^s \rangle$, $x^s = \{x_j^s\}$, где x_j^s — значение j -го входного, а y^s — значение выходного признака для s -го прецедента (экземпляра) выборки, $y^s \in \{1, 2, \dots, K\}$, где K — число классов, $K > 1$.

В случае, если исходный набор признаков $\{x_j\}$ имеет большой объем N , то синтезированная ДМ будет сложна для последующего анализа и обладать меньшим уровнем обобщения, поэтому возникает задача извлечения из исходного набора признаков $\{x_j\}$ наиболее информативного подмножества N' признаков $\{x'_i\}$, $i = 1, 2, \dots, N'$: $N' < N$, $Q_{п.}(x') \geq Q_{п.}(x)$, где $Q_{п.}$ — функционал качества набора признаков выборки.

Задача построения ДМ на основе ННС вида $y^s = f(w, x)$ в конструктивистской постановке [5] требует определения соответствующих структуры f и значений параметров ННС w по выборке $\langle x, y \rangle$.

Применительно к интегрированной ННС прямого распространения сигнала $\langle f, w \rangle$ задается кортежем $\langle M, \{N_\eta\}, \{y^{(\eta,i)}(x^{(\eta,i)})\} \rangle$ и описывается функционально формулой: $y_i^s = y^{(M,i)}(y^{(M-1,i)}(\dots y^{(1,i)}(x^s)))$, $i = 1, 2, \dots, N_{\eta-1}$, $w^{(\eta,i)} = \{w_j^{(\eta,i)}\}$, $y^{(0,j)} = \psi^{(0,j)} = x_j^s$, $N_0 = N$, $x_j^{(1,i)} = x_j^s$, $i = 1, 2, \dots, N_{\eta-1}$, $\eta = 1, 2, \dots, M$, $j = 1, 2, \dots, N$, где $\{y^{(\eta,i)} = \psi^{(\eta,i)}(\varphi^{(\eta,i)})\}$ и $w = \{w_j^{(\eta,i)}\} = \{w_j^{(\eta,i)}\}$ — соответственно, структурные блоки (узлы) и параметры ДМ на основе ННС; $\varphi^{(\eta,i)}$, $\psi^{(\eta,i)}$ — соответственно, дискриминантная (весовая) и активационная функции i -го узла η -го слоя; $w_j^{(\eta,i)}$ — значение j -го настраиваемого параметра или веса j -го входа i -го узла η -го слоя; $x_j^{(\eta,i)}$ — значение на j -м входе i -го узла η -го слоя; $y^{(\eta,i)}$ — значение на выходе i -го узла η -го слоя; N_η — число узлов в η -м слое; M — число слоев в ДМ на основе ННС.

Для задания структуры ДМ на основе ННС необходимо выделить нечеткие термы признаков, определить число узлов в ННС и в каждом ее слое, задать дискриминантные и активационные функции узлов, а также весовые коэффициенты (параметры) узлов [6].

Отметим, что обобщающие свойства ДМ на основе ННС будут тем выше, чем меньше будет в ДМ параметров, а поскольку основные настраиваемые параметры ННС — параметры функций принадлежности к нечетким термам, то для повышения обобщающих свойств ДМ на основе ННС необходимо сократить число нечетких термов. Сокращение числа нечетких термов также упростит последующий анализ ДМ и повысит ее интерпретабельность [7].

Для обеспечения высокого уровня автоматизации синтеза ДМ на основе ННС необходимо обеспечить автоматическое формирование нечетких термов без участия

человека либо при наличии экспертных знаний обеспечить их оптимизацию посредством обобщения.

Анализ литературы

Одним из наиболее известных подходов к решению задачи построения ДМ на основе ННС в автоматическом режиме, обеспечивающий обобщение данных, является использование кластер-анализа [3] для выделения правил как центров кластеров, получаемых по выборке данных с последующим отображением правил в структуру ННС и ее обучением на основе градиентных методов [4]. Недостатками такого подхода являются его неопределенность в числе искомым кластеров и начальных значениях их координат, высокая итеративность и сохранение всего набора признаков и термов в результирующем разбиении признакового пространства и получаемом наборе правил, и, как следствие, низкий уровень обобщения данных, а также избыточность получаемой ДМ и ее недостаточная интерпретабельность.

В [5, 7, 8] предложен комплекс методов построения ДМ в виде ННС на основе стохастического поиска. Данные методы позволяют синтезировать ДМ с учетом модели качества ННС [5], что позволяет обеспечить требуемые свойства у результирующей ДМ. Однако данный подход является высокоитеративным и медленным, но, в отличие от предыдущего подхода, позволяет решать задачи отбора признаков, выделения правил и формирования структуры ННС в автоматическом режиме.

Следовательно, необходимо разработать метод построения ДМ на основе ННС, свободный от недостатков рассмотренных выше методов.

Метод синтеза диагностической модели на основе нейро-нечетких сетей с высокими обобщающими свойствами

Для автоматизации формирования нечетких термов и выделения правил предлагается вместо использования процедур кластер-анализа выделить либо регулярные интервалы, либо использовать метод [5–8], позволяющий выделить интервалы с экземплярами одного класса каждый. Это позволит сформировать четкое разбиение пространства признаков, на основе которого по выборке прецедентов можно сформировать продукционные правила.

Очевидно, что как набор исходных признаков, набор выделенных термов, так и набор сформированных правил могут быть избыточными.

Поэтому для уменьшения избыточности данных необходимо сократить число используемых в ДМ признаков, а для повышения обобщающих свойств синтезируемой ДМ необходимо уменьшить число условий в антецедентах правил, а также сократить число самих правил (это позволит сократить число структурных элементов и число параметров ДМ).

На основе редуцированного разбиения признаков и набора правил можно определить параметры нечетких термов и сформировать нечеткие обобщенные правила, которые затем возможно отобразить в структуре и параметрах ННС.

Предлагаемый метод содержит следующие этапы.

Этап инициализации: задается обучающая выборка $\langle x, y \rangle$, $y \in \{0, 1\}$, $y \in \{1, 2, \dots, K\}$.

Этап формирования четкого разбиения пространства признаков: для выборки $\langle x, y \rangle$, формируется начальное разбиение признакового пространства на основе одного из следующих способов.

Способ 1. Диапазоны значений всех признаков разбивают на равное число интервалов одинаковой длины по каждому признаку. Границы интервалов значений признаков $\{ \langle l_{j,k}, r_{j,k} \rangle, j = 1, 2, \dots, N, k = 1, 2, \dots, k_j \}$, рассчитывают по формулам:

$$l_{j,k} = \min_{s=1,2,\dots,S} (x_j^s) + \frac{(k-1)}{k_j} \left(\max_{s=1,2,\dots,S} (x_j^s) - \min_{s=1,2,\dots,S} (x_j^s) \right),$$

$$r_{j,k} = \min_{s=1,2,\dots,S} (x_j^s) + \frac{k}{k_j} \left(\max_{s=1,2,\dots,S} (x_j^s) - \min_{s=1,2,\dots,S} (x_j^s) \right).$$

Значение k_j задается пользователем или выбирается автоматически, например, по формуле: $k_j = \text{round}(10 \ln S)$, где round — функция округления числа. При наличии возможности следует обеспечить объем выборок $S > 50$.

Достоинством данного способа является то, что параметры интервалов легко рассчитываются, а недостатками — то, что получаемое разбиение очень грубо аппроксимирует границы классов и может оказаться как чрезмерно избыточным, так и крайне недостаточным по числу выделенных интервалов и кластеров, а также требует предварительного задания числа кластеров, которое, как правило, заранее неизвестно.

Способ 2. Поскольку первый способ не учитывает топологические свойства обучающей выборки и может приводить к выделению большого числа кластеров, не содержащих экземпляров, для более точной аппроксимации границ классов предлагается учитывать минимальное расстояние между экземплярами для определения числа интервалов.

Первоначально для j -го признака, $j = 1, 2, \dots, N$, находятся минимальные и максимальные значения $\min(x_j)$ и $\max(x_j)$, на основе которых определяется длина интервала наблюдаемых значений j -го признака: $r_j = \max(x_j) - \min(x_j)$. После чего по оси j -го признака определяются одномерные расстояния между s -м и g -м экземплярами $\Delta_{j,s,g} = \Delta_{j,g,s} = |x_j^s - x_j^g|$, $s = 1, 2, \dots, S$, $g = s+1, s+2, \dots, S$. Далее для j -го признака, вычисляется масштабирующий коэффициент R_j на основе одной из формул:

$$R_j = \min_{\substack{s=1, 2, \dots, S; \\ g=s+1, s+2, \dots, S}} \{ \Delta_{j,s,g} \mid \Delta_{j,s,g} > 0 \}$$

или $R_j = \min_{\substack{s=1, 2, \dots, S; \\ g=s+1, s+2, \dots, S}} \{ \Delta_{j,s,g} \mid y^s \neq y^g, \Delta_j > 0 \}$, или $R_j = \frac{2}{S(S-1)} \sum_{s=1}^S \sum_{s+1}^S \Delta_{j,s,g}$.

Затем определяется число интервалов разбиения диапазона значений j -го признака k_j по одной из формул:

$$k_j = \text{round}(r_j / R_j) \text{ или } k_j = \begin{cases} \text{round}(r_j / R_j), & \text{round}(r_j / R_j) \leq S, \\ S, & \text{round}(r_j / R_j) > S. \end{cases}$$

После чего разбивается ось j -го признака на k_j интервалов, координаты левой и правой границ которых определяются аналогично первому способу.

Данный способ является вычислительно более трудоемким, по сравнению с предыдущим, однако позволит разбивать оси признаков на разное число интервалов, уменьшая как возможную избыточность, так и недостаточность разбиения. Недостатком данного способа является слабый учет топологии классов.

Способ 3. На основе метода [5–8] выделим интервалы значений $\{<l_{j,k}, r_{j,k}>\}$ по каждому j -му признаку, $j = 1, 2, \dots, N$, куда попадают только экземпляры, принадлежащие к одному и тому же классу. Достоинствами данного способа является более точная аппроксимация границ классов, по сравнению с первым способом, учет компактности расположения образов по каждому признаку отдельно, а недостатком — то, что требуется выполнять много операций сортировки для выделения интервалов по каждому признаку.

После формирования разбиения признакового пространства на основе одного из описанных выше способов необходимо определить для каждого k -го интервала значений j -го признака, $j = 1, 2, \dots, N$, $k = 1, 2, \dots, k_j$, номер класса:

$$K_{j,k} = \begin{cases} 0, & \neg \exists x^s, s = 1, 2, \dots, S: l_{j,k} \leq x_j^s \leq r_{j,k}, \\ y^s, & \forall y^s = y^g; s, g = 1, 2, \dots, S: l_{j,k} \leq x_j^s \leq r_{j,k}, l_{j,k} \leq x_j^g \leq r_{j,k}, \\ -1, & \exists y^s : y^s \neq y^g; s, g = 1, 2, \dots, S: l_{j,k} \leq x_j^s \leq r_{j,k}, l_{j,k} \leq x_j^g \leq r_{j,k}. \end{cases}$$

В результате выполнения данного этапа для выборки $\langle x, y \rangle$ получим интервалы значений признаков, которые будут описываться параметрами $\{l_{j,k}\}$, $\{r_{j,k}\}$, $\{K_{j,k}\}$, $\{k_j\}$.

Этап уточнения разбиения: для $\forall j = 1, 2, \dots, N, k = 1, 2, \dots, k_j$ выполняется исключение интервалов, в которые не попал ни один экземпляр обучающей выборки:

— если $K_{j,k-1} = K_{j,k+1}, K_{j,k} = 0$, тогда принять: $r_{j,k-1} = r_{j,k+1}$, после чего удалить k -й и $(k+1)$ -й интервалы, скорректировав соответствующим образом параметры разбиения;

— если $K_{j,k-1} \neq K_{j,k+1}, K_{j,k} = 0$, тогда принять: $r_{j,k-1} = r_{j,k-1} + 0,5(r_{j,k} - l_{j,k})$, $l_{j,k+1} = l_{j,k+1} - 0,5(r_{j,k} - l_{j,k})$, после чего удалить k -й интервал, скорректировав соответствующим образом параметры разбиения.

Далее для $\forall j = 1, 2, \dots, N, k = 1, 2, \dots, k_j$, осуществляется разбиение интервалов, содержащих экземпляры разных классов ($K_{j,k} = -1$): просматривая проекцию обучающей выборки на ось j -го признака в направлении возрастания его значений, на k -м интервале выделяются последовательно подинтервалы, внутри которых номер класса экземпляров остается неизменным, границы интервалов и их номера

классов добавляются в наборы $\{l_{j,k}\}$, $\{r_{j,k}\}$, $\{K_{j,k}\}$; при этом соответствующим образом корректируются параметры разбиения.

Этап повышения обобщающих свойств разбиения: обучающая выборка $\langle x, y \rangle$ относительно полученного разбиения представляется четкими продукционными правилами вида:

$$\{\bar{\mu}_{j,k}(x^s)\} \rightarrow y^s, s = 1, 2, \dots, S, j = 1, 2, \dots, N, k = 1, 2, \dots, k_j,$$

$$\text{где } \bar{\mu}_{j,k}(x^s) = \begin{cases} 1, l_{j,k} \leq x_j^s \leq r_{j,k}, \\ 0, \text{ в противном случае.} \end{cases}$$

Таким образом, каждый экземпляр обучающей выборки преобразуется в правило, причем значения признаков заменяются на принадлежности к четким термам-интервалам значений признаков.

Альтернативным вариантом представления данных правил является табличное представление, в котором в s -й строке располагается s -е правило, а в j -м столбце — k -номер термина j -го признака, в который попал s -й экземпляр по j -му признаку, т.е. для которого $\bar{\mu}_{j,k}(x^s) = 1$.

Для каждого s -го правила устанавливается показатель поддержки: $v_s = 1$.

Далее, до тех пор, пока возможно, в цикле выполняются действия:

— обобщение правил внутри каждого класса: если $\forall s = 1, 2, \dots, S, p = s + 1, s + 2, \dots, S : \exists s \neq p : y^s = y^p, \bar{\mu}_{j,k}(x^s) = \bar{\mu}_{j,k}(x^p), \forall j = 1, 2, \dots, N, k = 1, 2, \dots, k_j$, тогда можно сделать вывод о том, что правила, полученные на основе s -го и p -го экземпляров эквивалентны. Следовательно, из каждой группы эквивалентных правил следует оставить только одно, например, s^* -е правило, выполнив, таким образом, обобщение эквивалентных (дублирующихся) правил. При этом необходимо для s^* -го правила установить показатель поддержки v_{s^*} равным числу обобщенных правил;

— устранение избыточности антецедентов (условий) правил: осуществляется выявление таких комбинаций термов в антецедентах правил, которые позволяют однозначно разделять классы — последовательно рассматриваются все присутствующие в наборе правил комбинации термов разных признаков по 1, 2, ..., $N - 1$. Если текущая комбинация термов входит только в правила одного класса и отсутствует в правилах других классов, то ее термы можно считать разрешающими: $\forall s = 1, 2, \dots, S, q = 1, 2, \dots, K, z = 1, 2, \dots, K : \exists \langle j, k \rangle, j \in \{1, 2, \dots, N\}, k \in \{1, 2, \dots, k_j\} : \{\bar{\mu}_{i,p}(x^s) | \langle i, p \rangle \in \langle j, k \rangle\} \in \{\bar{\mu}_{i,p}(x^s) \rightarrow q\}, \{\bar{\mu}_{i,p}(x^s) | \langle i, p \rangle \in \langle j, k \rangle\} \notin \{\bar{\mu}_{i,p}(x^s) \rightarrow z | z \neq q\}$. После чего остальные (избыточные) термы, входящие в правила данного класса, содержащие разрешающую комбинацию, исключаются из соответствующих правил. Если имеется несколько разных разрешающих комбинаций, то следует отдать предпочтение той, которая входит в как можно большее число правил соответствующего класса и имеет наименьшую длину. Также целесообразно отдавать предпочтение термам тех признаков, которые содержат меньше всего термов, т.е. обеспечивают индивидуально лучшее разделение классов;

— обобщение признаков: выявляются признаки, эквивалентные на множестве правил. Для $\forall i = 1, 2, \dots, N, j = i + 1, i + 2, \dots, N$: признаки x_i и x_j являются качественно эквивалентными, если $k_i = k_j, \forall k = 1, 2, \dots, k_i : \bar{\mu}_{i,k}(x^s) = \bar{\mu}_{j,k}(x^s)$. Из каждой группы эквивалентных признаков следует оставить только один признак, скорректировав соответствующим образом набор правил и число признаков N ;

— обобщение термов признаков: выявляются термы разных признаков, эквивалентные на множестве правил. Для $\forall i = 1, 2, \dots, N, j = i + 1, i + 2, \dots, N, k = 1, 2, \dots, k_j, p = 1, 2, \dots, k_i$: k -й терм j -го признака и p -й терм i -го признака являются качественно эквивалентными, если $\forall s = 1, 2, \dots, S : \bar{\mu}_{i,k}(x^s) = \bar{\mu}_{j,p}(x^s)$. Из каждой группы эквивалентных термов разных признаков следует оставить только один терм у одного из признаков, скорректировав соответствующим образом набор правил и число термов соответствующих признаков. Если признаки, у которых выявлены эквивалентные между собой термы, содержат различное число термов, то следует оставлять терм у того признака, который содержит меньше всего термов (это обеспечит преимущество признакам, обеспечивающим лучшее разделение классов), но если признак содержит всего один терм, то терм и признак следует удалять (это позволит устранить малоинформативные признаки), оставляя терм у признака с наименьшим числом термов среди оставшихся признаков группы.

Этап формирования нечеткого разбиения: для редуцированного четкого разбиения признаков зададим функции принадлежности к интервалам значений признаков:

$$\mu_{j,k}(x_j^s) = \begin{cases} 0, & x_j^s \leq 0,5(l_{j,k} + r_{j,k-1}), \\ \frac{x_j^s - 0,5(l_{j,k} + r_{j,k-1})}{0,5(l_{j,k} - r_{j,k-1})}, & 0,5(l_{j,k} + r_{j,k-1}) \leq x_j^s < l_{j,k}, \\ 1, & l_{j,k} \leq x_j^s \leq r_{j,k}, \\ \frac{0,5(l_{j,k+1} + r_{j,k}) - x_j^s}{0,5(l_{j,k+1} - r_{j,k})}, & r_{j,k} \leq x_j^s < 0,5(r_{j,k} + l_{j,k+1}), \\ 0, & 0,5(r_{j,k} + l_{j,k+1}) \leq x_j^s, \end{cases}$$

где j — номер признака; k — номер интервала значений j -го признака.

Далее на основе редуцированного набора четких правил $\{\{\bar{\mu}_{j,k}(x^s)\} \rightarrow y^s\}$ сформируем набор нечетких продукционных правил:

$$\Pi = \left\{ \Pi^s : \bigwedge_{j,k} \left\{ \mu_{j,k}(x_j^s) \mid \bar{\mu}_{j,k}(x^s) \in \{\bar{\mu}_{j,p}(x^s)\} \rightarrow y^s, \bar{\mu}_{j,k}(x_j^s) \neq 0 \right\} \rightarrow y^s \right\}.$$

Этап синтеза ДМ на основе ННС: синтез ДМ на основе сформированного набора нечетких правил осуществляется в автоматическом режиме. При этом структура ННС задается в соответствии с рисунком, а параметры определяются итеративно по формулам:

$$\varphi_j^{(2,i)}(w_j^{(2,i)}, x_j^{(2,i)}) = \max\{w_j^{(2,i)}, x_j^{(2,i)}\}, i = 1, 2, \dots, S, j = 1, 2, \dots, \sum_{p=1}^N k_p,$$

$$\Psi^{(2,i)} = \min_{j=1, 2, \dots, \sum_{p=1}^N k_p} \{\varphi_j^{(2,i)}(w_j^{(2,i)}, x_j^{(2,i)})\}, i = 1, 2, \dots, S,$$

$$\varphi_j^{(3,i)}(w_j^{(3,i)}, x_j^{(3,i)}) = w_j^{(3,i)} x_j^{(3,i)}, i = 1, 2, \dots, K, j = 1, 2, \dots, S,$$

$$\Psi^{(3,i)}(\varphi_j^{(3,i)}) = \max_j \{\varphi_j^{(3,i)}(w_j^{(3,i)}, x_j^{(3,i)})\}, i = 1, 2, \dots, K, j = 1, 2, \dots, S,$$

$$\varphi^{(4,1)}(x^{(4,1)}) = \arg \max_{j=1, 2, \dots, K} \{x_j^{(4,1)}\},$$

$$\varphi^{(4,2)}(x^{(4,2)}) = \max_{j=1, 2, \dots, K} \{x_j^{(4,2)}\},$$

$$\Psi^{(4,i)}(\varphi^{(4,i)}) = \varphi^{(4,i)},$$

$$w_j^{(\eta,i)} = \begin{cases} 1, \mu_{z,v} \in \Pi^i, \eta = 2, i = 1, 2, \dots, S, j = v + (z-1) \sum_{p=1}^{z-1} k_{p-1}, z = 1, 2, \dots, N, v = 1, 2, \dots, k_z; \\ 0, \mu_{z,v} \notin \Pi^i, \eta = 2, i = 1, 2, \dots, S, j = v + (z-1) \sum_{p=1}^{z-1} k_{p-1}, z = 1, 2, \dots, N, v = 1, 2, \dots, k_z; \\ 0, \eta = 3, i = 1, 2, \dots, K, j = 1, 2, \dots, S, y^j \neq i, \\ \frac{v_j}{\max_{s=1, 2, \dots, S} \{v_s \mid y^s = i\}}, \eta = 3, i = 1, 2, \dots, K, j = 1, 2, \dots, S, y^j = i. \end{cases}$$




Схема структуры ДМ на основе ННС

На входы x_1, x_2, \dots, x_N синтезированной ННС подаются значения соответствующих признаков распознаваемого экземпляра. Узлы первого слоя ННС реализуют блоки определения принадлежностей распознаваемого экземпляра к термам признаков $\mu_{j,k}(x_j^s)$. Узлы второго слоя формируют антецеденты правил, а узлы третьего слоя — определяют значения консеквентов правил. Первый узел четвертого слоя определяет расчетный номер класса распознаваемого экземпляра y , а второй узел — коэффициент уверенности ДМ в принятом решении R_y .

Этап уточнения параметров ДМ: полученная ДМ на основе ННС тестируется и, если она не обеспечивает требуемый уровень точности, то к ННС могут быть применены для уточнения параметров разбиения методы обучения на основе обратного распространения ошибки [3] или на основе стохастического поиска [5, 7, 8].

Если же в результате дополнительной коррекции параметров разбиения не будет достигнут требуемый результат, то процесс синтеза ДМ следует повторить, увеличив число формируемых интервалов k_j на этапе формирования четкого разбиения при использовании первого и второго способов.

Если же увеличение числа формируемых интервалов не обеспечило требуемого уровня точности, но его дальнейший рост является невозможным вследствие достижения числа интервалов, равного числу экземпляров в выборке, то следует из множества правил выделить такие группы правил, у которых имеются одинаковые antecedentes, но разные консеквенты, и выявить таким образом противоречия правил в ДМ, для разрешения которого потребуется изменение исходного набора признаков, например, за счет добавления новых признаков, позволяющих устранять противоречия. Однако это сделает необходимым участие человека-эксперта.

Эксперименты и результаты

Для экспериментальной проверки работоспособности предложенного метода была разработана его программная реализация, с помощью которой проводились эксперименты по решению задач технического и биомедицинского диагностирования [5, 8]. Проведенные эксперименты подтвердили практическую применимость предложенного метода.

В частности, на основе предложенного метода решалась задача диагностирования лопаток газотурбинных авиадвигателей по спектрам свободных затухающих колебаний после ударного возбуждения [5, 8]. Исходный набор индивидуально малоинформативных признаков был преобразован в набор высокоинформативных конструктивных признаков на основе преобразований [9]. Фрагмент полученной обучающей выборки представлен в табл. 1.

Таблица 1. Фрагмент исходной обучающей выборки

S	x_1	x_2	x_3	x_4	x_5	y^s
1	1561608.07691579	1156924.51642006	14.1429532882317	10239.0059755342	5129	1
2	481913.317335243	469134.551511528	11.3582894087466	10239.0089454608	5121	1
3	335712.769373814	381372.954316449	16.1514885519001	10239.0352963783	5113	1
4	316584.82557242	326663.807676843	22.256147010374	10239.0687607216	5143	1
...
29	1691669.21754623	1272603.7378222	8.14766185201097	10239.0008639758	5088	0
30	502774.719415169	536006.570703204	6.27986574347985	10239.0031792217	5124	0
31	630933.080680252	489228.523923413	9.95707709579584	10239.0096772848	5134	0
32	1182173.29459429	1038063.82613548	10.782666758671	10239.0006640449	5109	0

На основе предложенного метода были сформированы термы и исходные правила, представленные слева в табл. 2. Затем посредством удаления термов и признаков были получены обобщенные правила, представленные в центре табл. 2.

В результате обобщения данных правил были получены правила, представленные справа в табл. 2.

Таблица 2. Таблица правил, сформированных по экземплярам выборки

Исходные правила							Обобщенные правила					
S	k					y ^s	Редукция признаков и термов			Редукция правил		
	x ₁	x ₂	x ₃	x ₄	x ₅		S	k x ₄	y ^s	S	k x ₄	y ^s
1	11	17	8	2	8	1	1	2	1	1	2	1
2	1	3	4	2	6	1	2	2	1	2	8	1
3	1	3	8	8	4	1	3	8	1	3	4	1
4	1	1	10	8	12	1	4	8	1	4	6	1
5	5	5	10	8	4	1	5	8	1	5	1	0
6	1	7	2	4	8	1	6	4	1	6	5	0
7	1	3	8	6	6	1	7	6	1	7	7	0
8	7	11	6	2	2	1	8	2	1	8	3	0
9	9	13	8	6	14	1	9	6	1			
10	9	15	8	8	8	1	10	8	1			
11	3	5	8	4	10	1	11	4	1			
12	9	13	8	4	6	1	12	4	1			
13	9	15	8	6	2	1	13	6	1			
14	9	13	8	6	4	1	14	6	1			
15	3	9	10	6	2	1	15	6	1			
16	1	3	10	8	6	1	16	8	1			
17	2	10	1	1	1	0	17	1	0			
18	6	2	7	5	7	0	18	5	0			
19	10	16	1	1	1	0	19	1	0			
20	10	16	1	1	3	0	20	1	0			
21	8	12	1	1	12	0	21	1	0			
22	10	16	1	1	3	0	22	1	0			
23	6	10	1	1	15	0	23	1	0			
24	4	8	1	1	13	0	24	1	0			
25	4	14	1	1	7	0	25	1	0			
26	10	16	9	7	1	0	26	7	0			
27	10	16	5	3	11	0	27	3	0			
28	4	10	1	1	5	0	28	1	0			
29	12	18	1	1	1	0	29	1	0			
30	2	6	1	1	7	0	30	1	0			
31	6	4	1	3	9	0	31	3	0			
32	10	16	3	1	3	0	32	1	0			

Из приведенных результатов в табл. 2 можно видеть, что предложенный метод позволил сократить число правил в 4 раза, число признаков — в 5 раз, а число используемых термов — в 7,9 раз. Таким образом, можно сделать вывод, что разработанный метод позволяет существенно повышать обобщающие свойства ДМ, существенно сокращать число ее структурных элементов и параметров (т.е. уменьшать сложность ДМ и увеличивать скорость работы ДМ при последовательной реализации вычислений на ЭВМ), упрощать правила и, следовательно, повышать интерпретируемость ДМ.

Заключение

В работе решена актуальная задача автоматизации процесса синтеза ДМ на основе ННС по прецедентам.

Научная новизна работы заключается в том, что впервые предложен метод синтеза ДМ на основе ННС, обладающих высокими обобщающими свойствами, который по выборке прецедентов в автоматическом режиме формирует разбиение признакового пространства, выделяет нечеткие термы, формирует набор продукционных правил на основе прецедентов, осуществляет редукцию избыточных термов и обобщает правила, после чего в неитеративном режиме синтезирует структуру и настраивает параметры ДМ на основе ННС. Это позволяет сократить число структурных элементов и число параметров ДМ, снизить ее сложность, повысить уровень обобщения и интерпретабельность, а также существенно сократить участие человека в процессе построения ДМ. Дополнительным преимуществом синтезируемых на основе предложенного метода ДМ является их способность давать субъективную оценку уверенности принимаемым решениям.

Дальнейшие исследования могут быть направлены на разработку более точных процедур формирования разбиения признакового пространства, а также апробации метода при решении практических задач технического и биомедицинского диагностирования.

1. *Технічне діагностування та контроль технічного стану. Терміни та визначення: ДСТУ 2389-94.* — [Чинний від 1995-01-01]. — К.: Держстандарт України, 1994. — 24 с. — (Національний стандарт України).

2. *Engelbrecht A. Computational intelligence: an introduction / A. Engelbrecht.* — Sidney: John Wiley & Sons, 2007. — 597 p.

3. *Рутковская Д. Нейронные сети, генетические алгоритмы и нечеткие системы / Д. Рутковская, М. Пилиньский, Л. Рутковский; пер. с польск. И.Д. Рудинского.* — М.: Горячая линия – Телеком, 2004. — 452 с.

4. *Митюшкин Ю.И. Soft Computing: идентификация закономерностей нечеткими базами знаний / Ю.И. Митюшкин, Б.И. Мокин, А.П. Ротштейн.* — Винница: Универсум-Винница, 2002. — 145 с.

5. *Интеллектуальные информационные технологии проектирования автоматизированных систем диагностирования и распознавания образов: монография / С.А. Субботин, Ан.А. Олейник, Е.А. Гофман, С.А. Зайцев, Ал.А. Олейник; под ред. С.А. Субботина.* — Харьков: ООО «Компания Смит», 2012. — 317 с.

6. *Субботін С.О. Подання й обробка знань у системах штучного інтелекту та підтримки прийняття рішень: навч. посібник / С.О. Субботін.* — Запоріжжя: ЗНТУ, 2008. — 341 с.

7. *Субботін С.О. Неітеративні, еволюційні та мультиагентні методи синтезу нечітко логічних і нейро-мережних моделей: монографія / С.О. Субботін, А.О. Олійник, О.О. Олійник; під заг. ред. С.О. Субботіна.* — Запоріжжя: ЗНТУ, 2009. — 375 с.

8. *Прогрессивные технологии моделирования, оптимизации и интеллектуальной автоматизации этапов жизненного цикла авиационных двигателей: монография / [А.В. Богуслаев, Ал.А. Олейник, Ан.А. Олейник, Д.В. Павленко, С.А. Субботин]; под ред. Д.В. Павленко, С.А. Субботина.* — Запорожье: ОАО «Мотор Сич», 2009. — 468 с.

9. *Субботин С.А. Формирование выборок и анализ качества моделей на основе нейронных и нейро-нечетких сетей в задачах диагностики и распознавания образов: монография / С.А. Субботин.* — Saarbrücken: LAP Lambert Academic Publishing, 2012. — 232 с. — ISBN 978-3-8473-4471-1.

Поступила в редакцию 18.08.2012