

СИНТЕЗ НЕЙРО-НЕЧЕТКИХ СЕТЕЙ НА ОСНОВЕ АССОЦИАТИВНЫХ ПРАВИЛ

Аннотация. Рассмотрена задача построения нейро-нечетких моделей. Разработан метод синтеза нейро-нечетких сетей на основе ассоциативных правил, который использует извлеченные из заданной транзакционной базы данных ассоциативные правила для определения структуры нейро-нечеткой сети, а также для вычисления значений параметров функций принадлежности и весовых коэффициентов. Создано программное обеспечение, реализующее предложенный метод. Решены задачи синтеза нейросетевых моделей для технического и медицинского диагностирования.

Ключевые слова: ассоциативное правило, нейро-нечеткая сеть, модель, база правил, транзакция, функция принадлежности.

ВВЕДЕНИЕ

В последние десятилетия при решении задач диагностирования, распознавания образов, а также количественного и качественного прогнозирования широкое применение на практике получили нейро-нечеткие сети (ННС), поскольку они позволяют обеспечивать приемлемую точность принятия решений, использовать имеющиеся экспертные знания в виде производственных правил при построении моделей, могут обучаться по прецедентам и являются интерпретабельными (удобными для восприятия и анализа человеком) [1, 2].

Традиционно применяемые для настройки параметров ННС градиентные методы, в том числе метод обратного распространения ошибки [1–5], являются высоко итеративными, требуют значительных временных затрат и памяти ЭВМ, не всегда позволяют достигать приемлемой точности принятия решений за ограниченное время. Кроме того, известные методы обучения ННС [1–5] предполагают наличие полной выборки данных, не содержащей пропусков. Однако в некоторых практических приложениях могут возникать ситуации, когда имеющаяся выборка содержит значительное число пропусков, что затрудняет применение градиентных методов настройки параметров. Поэтому актуальна задача разработки метода синтеза ННС, свободного от указанных недостатков.

В настоящей работе для синтеза ННС предлагается использовать ассоциативные правила [6–8], являющиеся импликациями $X \rightarrow Y$ и предназначенные для описания закономерностей вида «из события X следует событие Y » или «если X , то Y ». Методы извлечения таких правил [9–11] используются для обработки информации, представленной в виде транзакционных баз данных [6–11], в которых каждый элемент содержит информацию о некоторых взаимосвязанных событиях и представляется в виде списка событий. Возможность простого преобразования выборок данных, содержащих пропущенные значения, в наборы транзакций обуславливает целесообразность применения ассоциативных правил для построения ННС в условиях неполноты и неструктурированности данных.

Кроме того, использование ассоциативных правил для синтеза ННС целесообразно по следующим причинам.

Во-первых, применение методов извлечения ассоциативных правил из больших наборов данных для построения правил вида «если X , то Y » позволит существенно сократить массивы данных, уменьшая таким образом число экземпляров (транзакций) и признаков, описывающих исследуемые объекты и процессы. Это,

в свою очередь, упростит процесс построения моделей (уменьшится время синтеза и объем используемых аппаратных ресурсов компьютера), а также позволит синтезировать более простые модели, удобные для дальнейшего применения на практике.

Во-вторых, извлеченный набор ассоциативных правил можно использовать для выделения нечетких термов при синтезе ННС без существенного вовлечения человека в этот процесс, что позволит повысить уровень автоматизации информационной технологии, связанной с необходимостью построения нейро-нечетких моделей.

В-третьих, появится возможность дообучения ННС, синтезированной на основе набора ассоциативных правил, с помощью градиентных методов. При этом использование близкой к оптимальной начальной точки поиска (структуры и параметров ННС, полученных из набора ассоциативных правил) позволит существенно сократить временные затраты на построение ННС и уменьшить вероятность попадания в локальные оптимумы.

В-четвертых, в отличие от градиентных методов при построении ННС на основе ассоциативных правил не требуется вычисления значений частных производных целевой функции для определения значений весовых коэффициентов узлов-нейронов и параметров функций принадлежности к нечетким термам.

Целью настоящей работы является разработка метода синтеза нейро-нечетких сетей на основе ассоциативных правил.

ПОСТАНОВКА ЗАДАЧИ ПОСТРОЕНИЯ ННС

Пусть задана транзакционная база данных

$$D = \{T_1, T_2, \dots, T_{N_D}\}, \quad (1)$$

в которой каждый элемент T_j , $j = 1, 2, \dots, N_T$, содержит информацию о некоторых взаимосвязанных событиях, где $N_D = |D|$ — число элементов (транзакций) в наборе данных D . Элементы T_j можно представить следующим образом:

$$T_j = (tid_j, item_j),$$

где tid_j — идентификатор j -й транзакции T_j ; $item_j = \{t_{1j}, t_{2j}, \dots, t_{N_{item_j}j}\} \subseteq I$ — список элементов, входящих в транзакцию T_j ; t_{ij} — i -й элемент списка $item_j$, $i = 1, 2, \dots, N_{item_j}$; $N_{item_j} = |item_j|$ — число элементов множества $item_j$; $I = \{\tau_1, \tau_2, \dots, \tau_{N_I}\}$ — множество возможных значений, которые могут входить в список элементов $item_j$ каждой транзакции T_j , $j = 1, 2, \dots, N_T$, набора данных D ; τ_a — a -й элемент множества I , $a = 1, 2, \dots, N_I$; $N_I = |I|$ — число элементов множества I .

Тогда необходимо построить ННС (определить ее структуру и параметры) таким образом, чтобы был достигнут минимум заданного значения критерия оптимальности ННС:

$$\xi(\text{HNC}, D) \rightarrow \min,$$

где $\xi(\text{HNC}, D)$ — критерий, оценивающий эффективность применения ННС для аппроксимации зависимости между набором входных переменных $X = \{X_1, X_2, \dots, X_{N_X}\} \subset I$ и заданным выходным параметром $Y \subset I$, представленным в транзакционной базе данных D . В качестве критерия оптимальности ННС, как правило, применяется квадратичный критерий

$$\varepsilon = \sum_{p=1}^{N_D} (y_p - y(\text{HNC}, X_p))^2,$$

где $X_p \subset I$ — набор значений признаков в p -й транзакции базы данных D ; $y(\text{HNC}, X_p)$ — значение выхода ННС, вычисленное для набора значений X_p .

МЕТОД СИНТЕЗА НЕЙРО-НЕЧЕТКИХ СЕТЕЙ НА ОСНОВЕ АССОЦИАТИВНЫХ ПРАВИЛ

Разработанный метод основан на применении набора ассоциативных правил, извлекаемых из заданного набора данных D (1) и используемых для определения структуры ННС, а также для вычисления значений параметров функций принадлежности и весовых коэффициентов ННС.

Предлагаемый метод синтеза ННС состоит из следующих этапов.

Этап 1. Извлечение ассоциативных правил вида $X \rightarrow Y$ из заданного набора данных D . При этом заданной является также выходная переменная $Y \subset I$, модель зависимости которой от набора входных параметров $X = \{X_1, X_2, \dots, X_{N_X}\} \subset I$ необходимо построить. Выявление набора ассоциативных правил позволит существенно сократить размерность множества данных D (1), а также выделить нечеткие термы при синтезе ННС, определив таким образом ее структуру в автоматическом режиме, не требуя вовлечения пользователя в процесс структурного синтеза.

При решении задачи бинарной классификации (выходной параметр Y принимает одно из двух возможных значений) выполняется поиск позитивных правил вида $X \rightarrow Y$, характеризующих единичное значение выходного параметра Y , и негативных правил вида $X \rightarrow \bar{Y}$, которые отражают нулевое значение выходного параметра Y .

Поиск ассоциативных правил по заданному набору данных D можно выполнить с помощью одного из известных методов извлечения ассоциативных правил [6–9]. При этом процесс синтеза ассоциативных правил, как правило, выполняется следующим образом. Вначале генерируются все наборы X с уровнем поддержки, не ниже заданного экспертом порогового значения $\text{minsupport}(X)$, в результате чего формируются часто встречающиеся наборы $X \subset I$. Затем происходит формирование всех правил $X \rightarrow Y$ с уровнями достоверности и интересности, не ниже заданных экспертом пороговых значений $\text{minconfidence}(X \rightarrow Y)$ и ε_I соответственно. Таким образом, извлекается $N_{\text{поз.}}$ позитивных правил $X \rightarrow Y$, удовлетворяющих следующей системе условий:

$$\begin{cases} \text{supp}(X \rightarrow Y) \geq \text{minsupport}; \\ \text{conf}(X \rightarrow Y) \geq \text{minconfidence}; \\ |\text{supp}(X \rightarrow Y) / \text{supp}(X) \text{supp}(Y) - 1| \geq \varepsilon_I. \end{cases} \quad (2)$$

Извлеченные таким образом правила можно представить в виде

$$\text{правило } b_+ : \text{если } \bigcap_{a=1}^{N_{b_+}} X_a, \text{ то } Y = 1, b_+ = 1, 2, \dots, N_{\text{поз.}},$$

где N_{b_+} — число признаков в b_+ -м позитивном правиле $X \rightarrow Y$.

При извлечении негативных правил $X \rightarrow \bar{Y}$ из набора данных D поиск происходит среди таких транзакций T_j , в которых отсутствуют элементы $Y \subset I$. В результате извлекается $N_{\text{нег.}}$ негативных правил $X \rightarrow \bar{Y}$, удовлетворяющих следующему списку условий:

$$\begin{cases} (\text{supp}(X) \geq \text{minsupport}) \cap (\text{supp}(Y) \geq \text{minsupport}) \cap (\text{supp}(X \rightarrow \bar{Y}) \geq \text{minsupport}); \\ \text{conf}(X \rightarrow Y) \geq \text{minconfidence}; \\ |\text{supp}(X \rightarrow \bar{Y}) - \text{supp}(X) \text{supp}(\bar{Y})| \geq \varepsilon_I. \end{cases} \quad (3)$$

Выражения (3) позволяют выявлять достоверные негативные правила $X \rightarrow \bar{Y}$ с приемлемым уровнем поддержки, представляющие интерес в исследуемой предметной области и отражающие набор условий, выполнение которых

приведет к нулевому значению выходного параметра Y . Извлеченные негативные правила $X \rightarrow \bar{Y}$ описываются выражением

$$\text{правило } b_- : \text{если } \bigcap_{a=1}^{N_{b_-}} X_a, \text{ то } Y = 0, b_- = 1, 2, \dots, N_{\text{нег.}}, \quad (4)$$

где N_{b_-} — число признаков в b_- -м негативном правиле $X \rightarrow \bar{Y}$.

При количественных значениях выходного параметра Y и входных признаков X предлагается выполнять разбиение (дискретизацию) диапазона их возможных значений на интервалы. В результате такого разбиения каждая j -я транзакция $T_j = (tid_j, item_j)$ представляется списком элементов $item_j = \{t_{1j}, t_{2j}, \dots, t_{N_{item_j} j}\} \subseteq I$, в котором i -й элемент t_{ij} представляется в виде $t_{ij} = (\text{элемент } \tau_a \in I; \text{диапазон значений элемента } \tau_a)$, при этом множество $I = \{\tau_1, \tau_2, \dots, \tau_{N_I}\}$ возможных значений, которые могут входить в список элементов $item_j$ каждой транзакции T_j , содержит элементы τ_a :

$$\tau_a \in [\tau_{a \min}; \tau_{a \max}] = \bigcup_{c=1}^{N_{\text{разб. } \tau_a}} [\tau_{a \min c}; \tau_{a \max c}], \quad a = 1, 2, \dots, N_I,$$

где $\tau_{a \min}$ и $\tau_{a \max}$ — минимальное и максимальное значения, которые может принимать a -й элемент τ_a множества I ; $\tau_{a \min c}$ и $\tau_{a \max c}$ — минимальное и максимальное значения c -го интервала разбиения значений a -го элемента τ_a множества I ; $N_{\text{разб. } \tau_a}$ — число интервалов разбиения a -го элемента τ_a .

После дискретизации значений выходной Y и входных X переменных выполняется поиск ассоциативных правил $X \rightarrow Y$. Для этого используются методы извлечения ассоциативных правил, удовлетворяющих приведенным выше условиям (2). При таком поиске каждый диапазон дискретизации каждой переменной считается отдельным элементом, который можно использовать при построении ассоциативного правила. При этом последовательно извлекаются все правила для каждого возможного значения выходного параметра Y . Таким образом, выполняется поиск ассоциативных правил для каждого из $N_{\text{разб. } Y}$ диапазонов разбиения выходного параметра.

В результате такого поиска извлекаются $N_{\text{пр.}}$ правил вида

$$\text{правило } b : \text{если } \bigcap_{a=1}^{N_b} X_a \in [X_{a \min b}; X_{a \max b}], \text{ то } Y \in [Y_{\min b}; Y_{\max b}], \\ b = 1, 2, \dots, N_{\text{пр.}},$$

где N_b — число признаков в b -м правиле $X \rightarrow Y$; $X_{a \min b}$ и $X_{a \max b}$ — минимальное и максимальное значения признака X_a в b -м правиле соответственно; $Y_{\min b}$ и $Y_{\max b}$ — минимальное и максимальное значения выходного параметра Y в b -м правиле соответственно.

Этап 2. Построение базы правил вида «если X , то Y », определяющей структуру синтезируемой нейро-нечеткой модели. На данном этапе используются построенные ранее ассоциативные правила. В случае, если выходной параметр Y является качественным (при решении задач классификации), в базу правил вводится $N_{\text{поз.}}$ позитивных и $N_{\text{нег.}}$ негативных правил, найденных на предыдущем этапе. Таким образом, синтезируется следующая база, содержащая $N_{\text{поз.}} + N_{\text{нег.}}$ правил

$$\text{правило 1: если } \bigcap_{a=1}^{N_1} X_a, \text{ то } Y = 1;$$

.....

$$\begin{aligned}
&\text{правило } N_{\text{поз.}}: \text{ если } \bigcap_{a=1}^{N_{N_{\text{поз.}}}} X_a, \text{ то } Y = 1; \\
&\text{правило } N_{\text{поз.}} + 1: \text{ если } \bigcap_{a=1}^{N_{N_{\text{поз.}}+1}} X_a, \text{ то } Y = 0; \\
&\dots \\
&\text{правило } N_{\text{поз.}} + N_{\text{нег.}}: \text{ если } \bigcap_{a=1}^{N_{N_{\text{поз.}}+N_{\text{нег.}}}} X_a, \text{ то } Y = 0.
\end{aligned}$$

В случае, если выходной параметр Y и входные признаки X являются количественными, база правил строится на основе правил вида (4). В построенной базе правил по возможности выполняется объединение правил с соседними интервалами значений некоторых переменных, а также редукция избыточных правил. В результате синтезируется база из $N_{\text{пр.}}$ правил следующего вида:

$$\begin{aligned}
&\text{правило 1: если } \bigcap_{a=1}^{N_1} X_a \in [X_{a \min 1}; X_{a \max 1}], \text{ то } Y \in [Y_{\min 1}; Y_{\max 1}]; \\
&\text{правило 2: если } \bigcap_{a=1}^{N_2} X_a \in [X_{a \min 2}; X_{a \max 2}], \text{ то } Y \in [Y_{\min 2}; Y_{\max 2}]; \\
&\dots \\
&\text{правило } N_{\text{пр.}}: \text{ если } \bigcap_{a=1}^{N_{N_{\text{пр.}}}} X_a \in [X_{a \min N_{\text{пр.}}}; X_{a \max N_{\text{пр.}}}], \text{ то } Y \in [Y_{\min N_{\text{пр.}}}; Y_{\max N_{\text{пр.}}}].
\end{aligned}$$

Этап 3. Определение параметров первого слоя нейро-нечеткой сети. В разработанном методе в качестве базиса для построения нейро-нечетких моделей была выбрана сеть ANFIS [1, 2], которая реализует систему нечеткого вывода в виде пятислойной нейросети прямого распространения и является разновидностью сети Такаги–Сугэно–Канга [1, 2, 4]. Последняя имеет простую структуру и удобна для анализа и объяснения хода принятия решений.

Важно отметить, что предложенный метод можно использовать в модифицированном виде и для синтеза других типов нейро-нечетких сетей.

Нейроны первого слоя соответствуют нечетким термам входных переменных с функциями принадлежности $\mu_{ac}^{(1)}$, $a = 1, 2, \dots, N_X$, $c = 1, 2, \dots, N_{\text{разб. } a}$, где $\mu_{ac}^{(1)}$ — функция принадлежности a -го признака c -му терму; N_X — число входных параметров X в базе правил, синтезированной на предыдущем этапе; $N_{\text{разб. } a}$ — число интервалов разбиения a -го признака.

В случае, если признак X_a является качественным, значение величины $N_{\text{разб. } a}$ будет равно двум. Для количественных признаков значение величины $N_{\text{разб. } a}$ определяется в процессе дискретизации на этапе 1.

В качестве функции принадлежности предлагается использовать функцию Гаусса [1–5]

$$\mu_{ac} = \exp \left\{ -\frac{(X_a - M_{Xac})^2}{2\sigma_{Xac}^2} \right\}, \quad (5)$$

где M_{Xac} — математическое ожидание a -го признака X_a в c -м терме; σ_{Xac} — среднеквадратическое отклонение значений признака X_a в c -м терме от математического ожидания M_{Xac} , определяющее ширину функции μ_{ac} .

Таким образом, гауссова функция принадлежности μ_{ac} (5) характеризуется набором параметров (M_{Xac}, σ_{Xac}) . Определим значения параметров (M_{Xac}, σ_{Xac}) так, чтобы для каждого a -го признака ширина функции принадлежности μ_{ac} для c -го терма определялась исходя из границ диапазонов значений признака X_a на каждом интервале разбиения его значений, найденных ранее

$$M_{Xac} = \frac{1}{2}(X_{a\min c} + X_{a\max c}); \quad (6)$$

$$\sigma_{Xac} = \frac{X_{a\max c} - M_{Xac}}{2} = \frac{1}{4}(X_{a\max c} - X_{a\min c}). \quad (7)$$

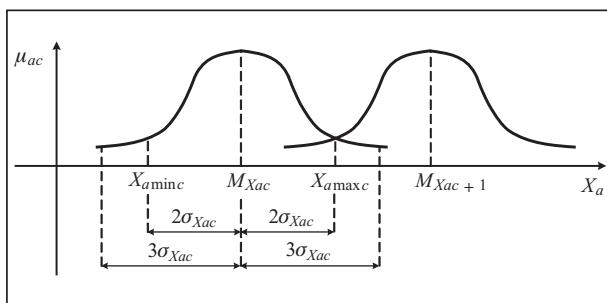


Рис. 1. График гауссовой функции μ_{ac} (5) с параметрами M_{Xac} и σ_{Xac} , рассчитанными по формулам (6) и (7)

Формулы (6) и (7) определяют соответственно значения параметров M_{Xac} и σ_{Xac} , рассчитанные таким образом, что величина M_{Xac} является серединой c -го интервала диапазона разбиения значений признака X_a , а величина σ_{Xac} определяет разброс значений признака X_a на c -м интервале (рис. 1).

Как видно из рис. 1, среднеквадратическое отклонение σ_{Xac} значений признака X_a в c -м терме подбирается так, чтобы полуширина c -го диапазона изменения значений a -го признака $[X_{a\min c}; X_{a\max c}]$ составляла $2\sigma_{Xac}$. В соответствии с законом 3σ [12] при гауссовом распределении 99 % всех чисел попадают в интервал $[M_X - 3\sigma; M_X + 3\sigma]$. Таким образом, некоторая часть значений признака X_a при использовании формул (6) и (7) попадет в интервалы $[M_X - 3\sigma; M_X - 2\sigma]$ и $[M_X + 2\sigma; M_X + 3\sigma]$. Поэтому построение гауссовых функций принадлежности μ_{ac} по формулам (6) и (7) обеспечивает возможность пересечения функций принадлежности соседних интервалов, что позволяет ввести нечеткость при определении принадлежности входных переменных термам.

Значения параметров M_{Xac} и σ_{Xac} рассчитываются по формулам (6) и (7) для всех интервалов диапазона разбиения a -го признака X_a : $c = 1, 2, 3, \dots, N_{\text{разб. } a}$.

Этап 4. Синтез скрытых слоев нейро-нечеткой сети. Второй слой содержит $N_{\text{пр.}}$ нейронов, на входы которых поступают выходы нейронов первого слоя, образующие антецеденты правил. Каждый b -й нейрон, $b = 1, 2, \dots, N_{\text{пр.}}$, этого слоя определяет степень выполнения соответствующего правила по одной из следующих формул:

$$\begin{aligned} \mu_b^{(2)} &= \min_{\substack{a=1, 2, \dots, N_X \\ c=1, 2, \dots, N_{\text{разб. } a}}} (w_{ac}^{(2,b)} \mu_{ac}^{(1)}), \\ \mu_b^{(2)} &= \prod_{a=1}^{N_X} \prod_{c=1}^{N_{\text{разб. } a}} w_{ac}^{(2,b)} \mu_{ac}^{(1)}, \end{aligned}$$

где $w_{ac}^{(2,b)}$ — весовые коэффициенты, определяющие наличие связи между нейронами первого слоя и соответствующими нейронами второго слоя и отражающие наличие c -го терма a -го признака в условии b -го правила: $w_{ac}^{(2,b)} = 1$, если c -й терм a -го признака входит в условие b -го правила, $w_{ac}^{(2,b)} = 0$ в противном случае.

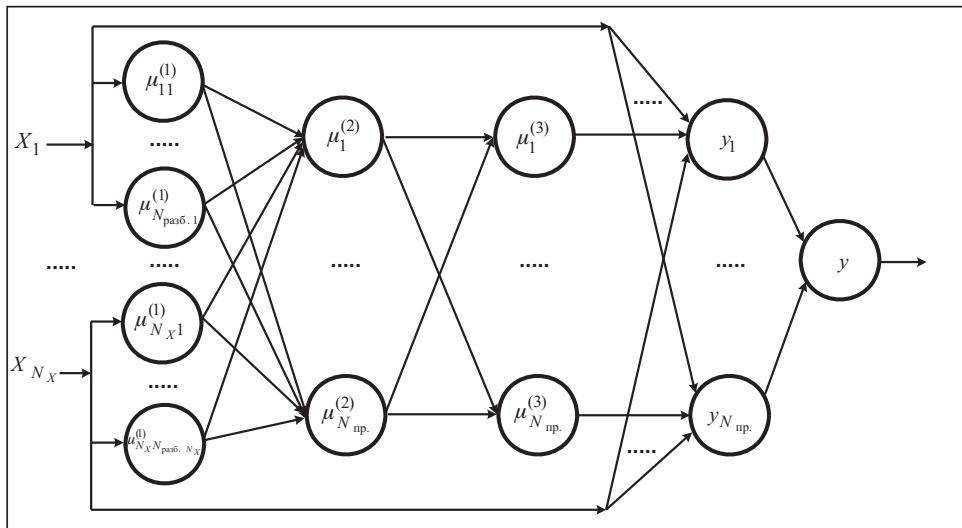


Рис. 2. Нейронечеткая сеть ANFIS

Нейроны третьего слоя находят нормализованные степени выполнения правил

$$\mu_b^{(3)} = \frac{\mu_b^{(2)}}{\sum_{c=1}^{N_{пр.}} \mu_c^{(2)}}, \quad b = 1, 2, \dots, N_{пр.}$$

Четвертый слой содержит нейроны, на выходах которых вычисляются линейные комбинации входных признаков X_a с учетом степеней выполнения правил (определяются консеквенты правил)

$$y_b = \mu_b^{(3)} \sum_{a=1}^{N_X} w_a^{(4,b)} X_a, \quad b = 1, 2, \dots, N_{пр.}$$

Каждый b -й нейрон четвертого слоя соединен со всеми входами сети X_a , $a = 1, 2, \dots, N_X$, а также с b -м нейроном третьего слоя.

Единственный нейрон пятого слоя сети предназначен для вычисления общего выхода сети

$$y = \sum_{b=1}^{N_{пр.}} y_b.$$

На рис. 2 приведена нейро-нечеткая сеть ANFIS, синтезированная с помощью предложенного метода.

Оценим вычислительную сложность описанного метода структурно-параллельного синтеза ННС.

Как отмечено выше, на первом этапе происходит извлечение ассоциативных правил из заданной транзакционной базы данных D (1), содержащей N_D транзакций, каждая из которых может описываться $|I|$ признаками. Вычислительную сложность данного процесса можно оценить [6–11] как $O(|I| \cdot N_D \log_2(N_D))$, где $O()$ — оператор нотации Ландау «о большое».

На втором этапе на основе извлеченных ранее ассоциативных правил выполняется построение базы, состоящей из $N_{пр.}$ правил. Поэтому оценку вычислительной сложности этого этапа определим как $O(N_{пр.})$.

Третий этап связан с определением параметров M_{Xac} и σ_{Xac} первого слоя нейро-нечеткой сети для каждого c -го терма ($c = 1, 2, \dots, N_{\text{разб.}a}$) a -го признака ($a = 1, 2, \dots, N_X$). Следовательно, сложность данного этапа можно определить как $O(N_{\text{разб.}a} \cdot N_X)$.

На этапе синтеза скрытых слоев нейро-нечеткой сети вычисляются значения $\mu_b^{(2)}, \mu_b^{(3)}, y_b$ для каждого b -го нейрона ($b = 1, 2, \dots, N_{\text{пр.}}$) скрытых слоев. Вычислительную сложность этого этапа оценим как $O(N_{\text{пр.}})$.

Исходя из сказанного выше, оценим вычислительную сложность предложенного метода структурно-параметрического синтеза ННС как

$$O_\Sigma = O(|I| \cdot N_D \log_2(N_D)) + O(N_{\text{пр.}}) + O(N_{\text{разб.}a} \cdot N_X) + O(N_{\text{пр.}}). \quad (8)$$

Очевидно, что число интервалов разбиения a -го признака $N_{\text{разб.}a}$ и число правил $N_{\text{пр.}}$ в синтезированной базе правил существенно меньше общего количества транзакций N_D в исходной базе транзакций D (1): $N_{\text{разб.}a} \ll N_D$, $N_{\text{пр.}} \ll N_D$. Кроме того, число входных параметров N_X в синтезированной базе правил не превышает общего количества признаков $|I|$ в транзакционной базе данных D ($N_X \leq |I|$). Поэтому оценки $O(N_{\text{пр.}})$ и $O(N_{\text{разб.}a} \cdot N_X)$ не превышают соответственно $O(N_D)$ и $O(N_D \cdot |I|)$. Следовательно, выражение (8) можно переписать в виде

$$\begin{aligned} O_\Sigma &= O(|I| \cdot N_D \log_2(N_D)) + O(N_D) + O(N_D \cdot |I|) + O(N_D) = \\ &= O(|I| \cdot N_D \log_2(N_D)). \end{aligned} \quad (9)$$

Поскольку оценка (9) предложенного метода структурно-параметрического синтеза ННС пропорциональна величине $N_D \log_2(N_D)$ и линейно зависит от количества признаков в исходной базе данных D , можно сделать вывод о том, что разработанный метод сокращения эффективен.

ЭКСПЕРИМЕНТЫ И РЕЗУЛЬТАТЫ

Предложенный метод построения ННС на основе ассоциативных правил программно реализован на языке программирования C#. Для экспериментального исследования предложенного метода, а также сравнения его с существующими аналогами решались практические задачи диагностирования и распознавания образов [13], численные характеристики которых приведены в табл. 1.

Как видно из табл. 1, практические задачи характеризуются различным числом признаков и экземпляров, а также имеют разный формат представления данных, что позволяет проиллюстрировать работу предложенного метода и сравнить его с существующими аналогами при различных входных данных.

При экспериментальном исследовании сравнивались следующие методы синтеза ННС:

1) метод, при использовании которого выборка данных отображается непосредственно в правила (каждый экземпляр выборки преобразуется в одно правило базы правил), таким образом формируя структуру сети. Настройка параметров нейроэлементов (параметрический синтез) осуществляется с помощью метода обратного распространения ошибки [1–5, 14];

2) метод, предусматривающий кластеризацию выборки. При использовании такого подхода на основании найденных центров кластеров формируются правила, которые отображаются в структуру ННС. Параметры блоков ННС настраиваются с помощью метода обратного распространения ошибки [1–5, 14];

3) предложенный метод структурно-параметрического синтеза ННС на основе ассоциативных правил.

Таблица 1. Характеристики исходных задач

Название задачи	Количество входных признаков	Количество экземпляров	Формат представления данных
1. Диагностирование лопаток турбины высокого давления газотурбинного авиадвигателя	515	32	Таблично заданная выборка данных
2. Моделирование зависимости частоты собственных колебаний от геометрических параметров <u>пера лопаток</u>	33	100	—“—
3. Моделирование взаимосвязей параметров испытаний авиадвигателей в процессе проливки сопловых аппаратов	6	491	—“—
4. Диагностирование кузовов автотранспортных средств	48	172	—“—
5. Диагностирование нейро-артических аномалий (неструктурированный массив данных)	39	344	Транзакционная база данных
6. Диагностирование качества кондитерской продукции	43	956	—“—

Для экспериментального сравнения предложенного метода с существующими аналогами использовались критерии, учитывающие различные характеристики синтезированных нейро-нечетких моделей. В качестве критериев сравнения выбраны следующие:

- ошибка ННС, синтезированной на основе обучающего множества данных ε_0 ;
- ошибка ННС, рассчитанная для тестового множества данных ε_t ;
- структурная сложность синтезированной ННС β_s , определяемая как число используемых нейроэлементов;
- параметрическая сложность β_p — общее число параметров модели (весовых коэффициентов и параметров функции принадлежности).

Результаты экспериментального исследования приведены в табл. 2.

Как видно из табл. 2, первый из сравниваемых методов, в котором выборка отображается в правила, а настройка параметров нейроэлементов осуществляется с помощью обратного распространения ошибки, обеспечил построение нейросетевых моделей, характеризующихся невысокими значениями ошибки ε_{01} , рассчитанной на основе обучающего множества данных (значение ε_{01} для различных задач составило от 2,9 до 3,1 %, что приемлемо для решаемых задач). Однако синтезированные таким образом ННС характеризовались высокими значениями критериев структурной β_{s1} и параметрической β_{p1} сложности, существенно превышающими значения аналогичных критериев моделей, построенных с помощью других методов. Это вызвано тем, что данный подход подразумевает непосредственное отображение исходной выборки в правила, что приводит к избыточности синтезируемой таким образом сети (высокие значения β_{s1} и β_{p1}) с низкими способностями к обобщению данных (значение ошибки ε_{t1} , рассчитанной для тестового множества данных, существенно превышает значения, аналогичные для ННС, синтезированных с помощью второго и третьего методов).

Применение предложенного метода структурно-параметрического синтеза ННС обеспечивает построение нейро-нечетких моделей с существенно меньшими значениями показателей структурной и параметрической сложности по сравнению с методом, подразумевающим отображение исходной выборки в правила

(например, для первой задачи $\beta_{s3} = 216$ и $\beta_{p3} = 1127$), поскольку разработанный метод предполагает построение структуры ННС на основе ассоциативных правил, извлеченных из исходного множества D , обеспечивая таким образом сокращение избыточности информации.

Таблица 2. Результаты экспериментов

Название задачи	Значения критериев сравнения для методов синтеза ННС											
	Обучение на основе обратного распространения ошибки								Предложенный метод			
	Синтез структуры ННС отображением экземпляров в правила				Синтез структуры ННС отображением центров кластеров в правила							
	ε_{01}	ε_{t1}	β_{s1}	β_{p1}	ε_{02}	ε_{t2}	β_{s2}	β_{p2}	ε_{03}	ε_{t3}	β_{s3}	β_{p3}
1. Диагностирование лопаток турбины высокого давления газотурбинного авиадвигателя	3,1	15,6	1127	51558	6,25	9,4	1037	4128	3,1	9,4	216	1148
2. Моделирование зависимости частоты собственных колебаний от геометрических параметров пера лопаток	3,0	12,0	466	30165	4,0	7,0	181	1190	2,0	5,0	184	1401
3. Моделирование взаимосвязей параметров испытаний авиадвигателей в процессе проливки сопловых аппаратов	3,1	9,2	1504	25976	2,6	4,1	88	1113	1,3	2,4	103	1518
4. Диагностирование кузовов автотранспортных средств	2,9	8,7	757	79704	1,7	2,9	274	3551	1,2	3,5	154	1847
5. Диагностирование нейро-артритических аномалий (неструктурированный массив данных)	—	—	—	—	—	—	—	—	2,3	3,8	235	3432
6. Диагностирование качества кондитерской продукции	—	—	—	—	—	—	—	—	3,5	4,4	1102	1641

Сравнение предложенного метода синтеза ННС и метода, предполагающего кластеризацию данных при структурном синтезе ННС, показывает, что в некоторых случаях (при больших количествах исходных признаков, задачи 1 и 4) предложенный метод обеспечивал построение более простых нейромоделей (например, для первой задачи $\beta_{s3} = 216$, $\beta_{p3} = 1148$ по сравнению с $\beta_{s2} = 1037$, $\beta_{p2} = 4128$), поскольку позволял сократить исходную выборку путем выделения набора правил и, в отличие от второго и первого методов, исключения некоторых неинформативных признаков. В задачах с небольшим числом признаков в исходной выборке метод, предполагающий кластеризацию данных, позволил синтезировать нейро-нечеткие модели с лучшими значениями характеристик структурной и параметрической сложности (например, для третьей задачи

$\beta_{s2} = 88$, $\beta_{p2} = 1113$ по сравнению с $\beta_{s3} = 103$, $\beta_{p3} = 1518$), однако точность синтезированных нейросетевых моделей с помощью предложенного метода была несколько выше ($\varepsilon_{02} = 2,6$, $\varepsilon_{t2} = 4,1$ по сравнению с $\varepsilon_{03} = 1,3$, $\varepsilon_{t3} = 2,4$), что характеризует данный метод.

Анализ результатов табл. 2 показал, что разработанный метод структурно-параметрического синтеза ННС позволяет построить нейро-нечеткие модели с приемлемыми аппроксимационными (невысокие значения ошибки ε_{03} , рассчитанной для обучающего множества) и обобщающими (невысокие значения критерия ε_{t3}) способностями, обеспечивая таким образом приемлемую точность принятия решений. Нейро-нечеткие модели, синтезированные на основе разработанного метода, характеризуются низкими значениями оценок структурной β_{s3} и параметрической β_{p3} сложности, что свидетельствует об их относительно высокой интерпретабельности (удобства для восприятия и анализа человеком), что обеспечивается извлечением ассоциативных правил, позволяющих обобщить в виде базы правил информацию об исследуемом объекте или процессе.

Важно отметить, что предложенный метод в отличие от известных позволил также решить задачи 5 и 6, в которых входная информация представлена в виде транзакционных баз данных, где каждая транзакция могла содержать значения лишь некоторых из всего множества признаков τ_a . Наличие пропущенных значений (например, ситуации, когда для некоторых пациентов T_j имелись результаты различных лабораторных исследований, описываемых разными характеристиками τ_a) не позволяло преобразовать исходное множество данных в форму таблично заданной выборки, а, следовательно, и применять известные методы для синтеза нейро-нечетких моделей.

Таким образом, предложенный метод синтеза нейро-нечетких сетей основан на применении извлеченного из заданной транзакционной базы данных набора ассоциативных правил, используемых для определения структуры ННС, а также для вычисления значений параметров функций принадлежности и весовых коэффициентов ННС, что позволяет синтезировать простые нейромодели, удобные для дальнейшего применения на практике.

ЗАКЛЮЧЕНИЕ

В работе решена актуальная задача автоматизации построения диагностических моделей на основе нейро-нечетких сетей, синтезируемых по набору прецедентов.

Научная новизна работы заключается в том, что разработан новый метод структурно-параметрического синтеза нейро-нечетких сетей, который основан на применении извлеченного из заданной транзакционной базы данных набора ассоциативных правил, используемых для определения структуры ННС, а также для вычисления значений параметров функций принадлежности и весовых коэффициентов ННС, что позволяет строить ННС на основании неструктурированных наборов данных, в которых каждый экземпляр представляется транзакцией, описывающей конкретную последовательность некоторых взаимосвязанных событий.

Применение методов извлечения ассоциативных правил для синтеза ННС позволяет существенно сокращать массивы данных, уменьшая таким образом число экземпляров (транзакций) и признаков, описывающих исследуемые объекты и процессы, что, в свою очередь, упрощает в дальнейшем процесс построения моделей (уменьшается время синтеза и количество используемых аппаратных ресурсов компьютера), а также позволяет синтезировать более простые модели, удобные для дальнейшего применения на практике.

Предложенный метод использует построенный набор ассоциативных правил для выделения нечетких термов при синтезе ННС без участия человека в этом

процессе, что позволяет повысить уровень автоматизации информационной технологии, связанной с необходимостью построения нейро-нечетких моделей.

В отличие от градиентных методов в предложенном методе синтеза ННС на основе ассоциативных правил не требуется вычисления значений частных производных целевой функции для определения значений весовых коэффициентов нейронов и параметров функций принадлежности.

Практическая ценность полученных результатов заключается в том, что на основе предложенного метода разработано программное обеспечение, позволяющее выполнять синтез нейро-нечетких сетей на основе ассоциативных правил, а также решены практические задачи технического и медицинского диагностирования.

СПИСОК ЛИТЕРАТУРЫ

1. Jang J.R., Sun C.-T., Mizutani E. Neuro-fuzzy and soft computing: a computational approach to learning and machine intelligence. — Upper Saddle River: Prentice-Hall, 1997. — 614 p.
2. Jang J.R. ANFIS: Adaptive-network-based fuzzy inference system // IEEE Transactions on Systems and Cybernetics. — 1993. — 23. — P. 665–685.
3. Zadeh L.A. Fuzzy logic, neural networks, and soft computing // Communications of the ACM. — 1994. — 37, N 3. — P. 77–84.
4. Nauck D., Klawonn F., Kruse R. Foundations of neuro-fuzzy systems. — Chichester: John Wiley & Sons, 1997. — 305 p.
5. Методы робастного, нейро-нечеткого и адаптивного управления: учебник / Под ред. Н.Д. Егупова. — М.: МГТУ им. Н.Э. Баумана, 2001. — 744 с.
6. Zhang C., Zhang S. Association rule mining: models and algorithms. — Berlin: Springer-Verlag, 2002. — 238 p.
7. Gkoulalas-Divanis A., Verykios V.S. Association rule hiding for data mining. — New York: Springer-Verlag, 2010. — 150 p.
8. Zhao Y., Zhang C., Cao L. Post-mining of association rules: techniques for effective knowledge extraction. — New York: Information Science Reference. — 2009. — 372 p.
9. Adamo J.-M. Data mining for association rules and sequential patterns: sequential and parallel algorithms. — New York: Springer-Verlag, 2001. — 259 p.
10. Koh Y.S., Rountree N. Rare association rule mining and knowledge discovery. — New York: Information Science Reference, 2009. — 320 p.
11. Au W.-H., Chan K.C. Mining fuzzy association rules in a bank-account database // IEEE Transactions on Fuzzy Systems. — 2003. — 2, N 11. — P. 238–248.
12. Айвазян С.А., Енюков И.С., Мешалкин Л.Д. Прикладная статистика. Исследование зависимостей. — М.: Финансы и статистика, 1985. — 487 с.
13. Интеллектуальные информационные технологии проектирования автоматизированных систем диагностирования и распознавания образов / С.А. Субботин, Ан.А. Олейник, Е.А. Гофман и др. — Харьков: ООО «Компания Смит», 2012. — 317 с.
14. Rutkowski L. Flexible neuro-fuzzy systems: structures, learning and performance evaluation. — Boston: Kluwer, 2004. — 276 p.

Поступила 03.07.2012
После доработки 27.01.2014