

ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ

УДК 004.8

Н.А. Новоселова

ПОСТРОЕНИЕ НЕЧЕТКОЙ НЕЙРОСЕТЕВОЙ МОДЕЛИ
ДЛЯ РЕШЕНИЯ ЗАДАЧ КЛАССИФИКАЦИИ

Рассматривается процесс построения нечеткой нейросетевой классифицирующей модели (ННМ) на основе имеющихся числовых значений признаков. Показано, что интегрирование нейронных сетей и нечетких систем позволяет создавать гибридные модели, которые способны обучаться на данных посредством минимизации соответствующей функции ошибки классификации и одновременно представлять извлекаемые из данных знания в виде набора лингвистических классифицирующих правил. В связи с необходимостью построения ННМ, обладающей достаточной степенью интерпретируемости при сохранении точности классификации, предлагается использовать трехэтапный подход к генерированию набора нечетких классифицирующих правил, которые явным образом представляют знания, содержащиеся в данных.

Введение

Задача классификации является одной из наиболее важных задач анализа данных и состоит в отнесении некоторого объекта, характеризующегося набором признаков, к одному из нескольких predetermined классов. Для решения задачи классификации применяются как классические статистические методы, так и методы из области машинного обучения. Решение задачи классификации состоит в построении модели задачи и оценке ее параметров на основе имеющихся данных. Однако при использовании традиционных подходов в большинстве случаев получаемая модель, даже обладая достаточно высокой эффективностью, не является интуитивно понятной конечному пользователю и не позволяет оценить заложенные в ней знания, на основе которых должна происходить классификация. В этих случаях более прозрачной является модель, которая представлена в виде набора лингвистических классифицирующих правил. Такие наборы лингвистических правил помогают пользователю понять лежащий в основе классификации процесс. Таким образом, использование нечеткого моделирования для решения практических задач классификации обусловлено необходимостью и возможностью получения компактных и интерпретируемых наборов правил. Нечеткая модель позволяет определить частично известную связь между независимыми числовыми признаками, характеризующими объект и представленными в виде набора предпосылок нечетких правил, и зависимым категориальным признаком, определяющим классы. Первоначально нечеткие модели строились на основе знаний экспертов, представляемых нечеткими правилами, и использовались в виде нечетких контроллеров или нечетких экспертных систем, однако в связи со сложностью моделируемых процессов такие модели обладали недостаточной эффективностью. Так возникла необходимость обучения структуры и параметров нечетких моделей на основе имеющихся данных. М.Сугено одним из первых предложил самообучающуюся нечеткую систему вывода [1]. В настоящее время существует множество различных подходов к автоматическому построению нечеткой модели, в том числе и для задач классификации. К таким подходам можно отнести нейросетевое нечеткое моделирование, генерирование нечетких правил на основе генетических алгоритмов, нечеткую кластеризацию и т. д.

Для решения задачи классификации использовалась нейросетевая организация нечеткой модели, позволяющая в упрощенном виде представить нечеткую систему вывода и применить модифицированные нейросетевые алгоритмы для адаптивного обучения параметров такой нечеткой модели. Однако процесс построения ННМ с использованием набора данных не гарантирует получения легко интерпретируемого набора правил, а требует дополнительных усилий по его оптимизации, принимая во внимание выбор оптимального соотношения

между точностью классификации (вероятностью безошибочной классификации) и интерпретируемостью модели.

Таким образом, в настоящей работе представлен процесс построения нечеткой нейросетевой модели, обеспечивающей получение интерпретируемого набора классифицирующих правил. Данный процесс можно разделить на три этапа [2]:

1. Инициализация структуры ННМ. Происходит определение количества нечетких множеств, задаваемых функциями принадлежности для каждого признака, определение начального количества классифицирующих правил. Используется структурно-ориентированный метод инициализации начальной структуры ННМ, позволяющий применять имеющийся набор числовых значений признаков (данных) для построения соответствующего набора начальных классифицирующих правил.

2. Обучение параметров ННМ. Происходит обучение параметров функций принадлежности (уточнение формы, положения носителя на оси значений признака) с использованием специально разработанного адаптивного эвристического метода.

3. Оптимизация структуры ННМ. Происходит упрощение структуры ННМ с применением четырех специально разработанных алгоритмов, позволяющих удалить избыточные признаки из предпосылок набора правил, правила с использованием коэффициента их эффективности, элементы предпосылки правила и нечеткие множества для каждого из признаков, не увеличивая при этом общую ошибку классификации.

1. Определение нечеткого классификатора, архитектура и свойства нечеткой нейросетевой модели

Нечеткий классификатор представляет собой систему нечетких правил, которые описывают m классов в имеющемся наборе исходных данных, и нечеткую систему вывода для их переработки с целью получения результата классификации [3]. Предпосылки правил задают область действия правил в n -мерном признаковом пространстве, а следствиями правил являются метки классов из множества $t \in \{C_1, \dots, C_m\}$:

$$\text{Правило } R_j: \text{ если } p_1 \in \mu_j^1 \text{ и } \dots \text{ } p_n \in \mu_j^n, \text{ то } t_j, j=1, \dots, M, \quad (1)$$

где M – количество правил; n – количество признаков; $p = [p_1, p_2, \dots, p_n]^T$ – входной вектор признаков; t_j – следствие j -го правила; μ_j^1, \dots, μ_j^n – функции принадлежности нечетких множеств. Логическая связка «и» моделируется оператором произведения или оператором минимум и определяет связь между отдельными элементами предпосылки. Следовательно, степень активации j -го правила рассчитывается следующим образом:

$$\beta_j(\vec{x}) = \prod_{i=1}^n \mu_j^i(x_i) \text{ или } \beta_j(\vec{x}) = \min_{1 \leq i \leq n} (\mu_j^i(x_i)), \quad j = 1, 2, \dots, M.$$

Выход классификатора определяется согласно стратегии «победитель забирает все», т. е. выходом является класс, соответствующий следствию правила с наибольшей степенью активации:

$$y = t_{j^*}, \quad j^* = \arg \max_{1 \leq j \leq M} (\beta_j).$$

Степень достоверности результата определяется нормализованной степенью активации правила

$$CF = \beta_{j^*} / \sum_j \beta_j.$$

ННМ представляет собой сочетание нейронной сети и нечеткого классификатора в единой однородной архитектуре и характеризуется следующими свойствами:

- является нечетким классификатором, представленным в виде нейронной сети прямого распространения и обучаемым с использованием эвристического нейросетевого алгоритма;
- может быть интерпретирована как набор нечетких правил вывода;
- алгоритм обучения ННМ учитывает семантику нечеткой модели с целью сохранения ее лингвистической интерпретируемости.

В нейросетевом представлении нечеткого классификатора нечеткие множества числовых признаков задают веса соединений входного и скрытого слоев нейронной сети, а входные/выходные признаки и правила представляют собой нейроны входного/выходного и скрытого слоев сети (рис. 1). Так как нечеткие классификаторы не используют нечеткие множества в следствиях правил, нейроны правил напрямую соединены через невзвешенные соединения (или через соединения с постоянным весом, равным 1) с нейронами выходного слоя, представляющими метки классов. Так как предпосылка каждого правила использует в качестве следствия только одну метку класса, то имеется только одно соединение между каждым нейроном правила и выходным слоем.

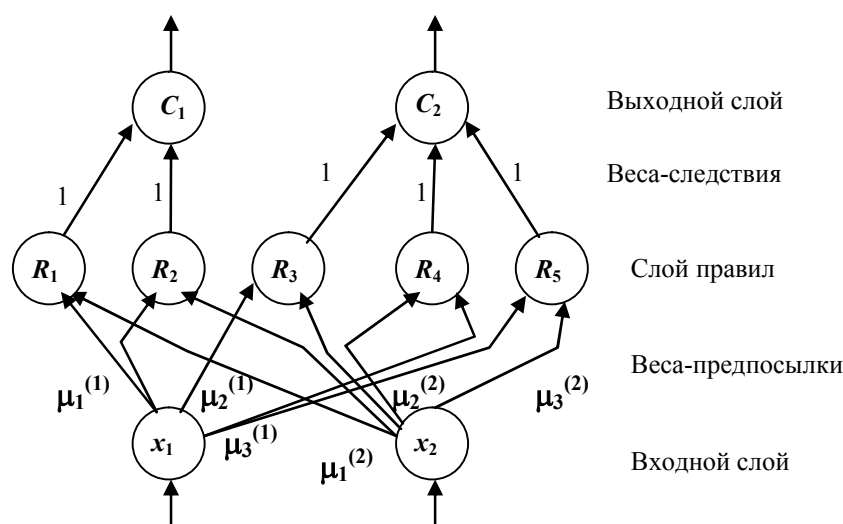


Рис. 1. Нейросетевое представление нечеткого классификатора с пятью правилами и двумя классами

Таким образом, ННМ представляет собой трехслойную сеть прямого распространения, имеющую следующую структуру:

- первый слой (входные признаки);
- скрытый слой (нечеткие правила);
- третий слой (выходные признаки);
- в качестве функций активации используются t -нормы и t -конормы [3], а именно функции минимума и максимума;
- нечеткие множества (веса соединений).

2. Структурно-ориентированный метод инициализация нечеткой нейросетевой модели

Существует три основных подхода к построению начальной структуры нечеткого классификатора:

1. Равномерное разбиение пространства значений признаков на нечеткие множества и построение решетки в многомерном пространстве исходных признаков [4]. Каждая ячейка решетки определяет отдельное правило. В случае n -мерного пространства признаков, разбитых на M нечетких множеств, максимальное количество возможных правил равно M^n . Рассмотрение этих правил при большом количестве признаков является неэффективным. Положительным

свойством такого подхода является хорошая лингвистическая интерпретируемость полученных правил. Х. Ишибучи в своих работах [5] использовал начальное равномерное разбиение многомерного пространства исходных данных для построения интерпретируемых нечетких классификаторов с применением генетического алгоритма.

2. Построение на основе исходных данных классифицирующего дерева решений. Дерево решений разбивает многомерное пространство значений признаков на отдельные области, представляющие собой четкие правила классификации, которыми инициализируется нечеткая нейросетевая модель [6]. В связи с тем что нечеткие правила вывода обладают свойством интерполяции между перекрывающимися нечеткими множествами и результирующая граница классификации может быть сглаженной и не параллельной отдельным осям признаков, результирующий набор правил после настройки параметров функций принадлежности и сокращения избыточных правил является более компактным и интерпретируемым.

3. Инициализация структуры нечеткого классификатора с использованием результатов нечеткой кластеризации [7]. Применение данного метода позволяет получить более компактную начальную структуру нечеткого классификатора и упростить процесс построения оптимального набора правил, однако сам процесс нечеткой кластеризации является достаточно непростым, так как требует изначального определения количества кластеров C в данных. Кроме того, результатом процесса кластеризации является C многомерных функций принадлежности. Одномерные нечеткие множества μ_j^i для классифицирующих правил, представленных в выражении (1), определяются проецированием многомерных функций на оси входных признаков x_i . После этого области, соответствующие правилам и определяемые комбинацией одномерных нечетких множеств, уже не будут полностью соответствовать исходным многомерным областями. Кроме того, полученные нечеткие множества для каждого из признаков могут быть неразличимы, что ухудшает интерпретируемость результатов.

Предлагаемый в настоящей работе структурно-ориентированный метод инициализации ННМ базируется на первом из описанных выше подходов к построению начальной структуры ННМ и позволяет ограничить количество изначально построенных правил с помощью обучающего набора данных [8]. Метод предполагает начальное нечеткое разбиение области значений всех входных признаков для дальнейшего создания набора нечетких правил вывода. В отличие от других методов, структурно-ориентированное обучение нейросетевой нечеткой модели имеет ряд преимуществ:

- позволяет создавать легко интерпретируемые лингвистически наборы правил;
- является быстрым в вычислительном плане и легко реализуемым;
- может использоваться как для числовых, так и для категориальных данных;
- может использоваться при наличии пропущенных данных.

Рассмотрим краткое описание метода. Все пространства значений независимых признаков разбиваются на нечеткие множества. Данная процедура выполняется или экспертом, или автоматически путем равномерного разбиения пространства значений признаков с использованием равноотстоящих перекрывающихся функций принадлежности, например треугольных, трапециевидных или гауссовых. Количество функций принадлежности определяет глубину детализации пространства признаков. Правила создаются в процессе обработки множества обучающих данных. В начале обучения набор правил или является пустым, или содержит некоторые правила, определяющие первоначальные знания. На первом этапе создаются все необходимые предпосылки правил вывода. Для каждого элемента обучающего множества отбирается комбинация соответствующих нечетких множеств, дающих максимум функции принадлежности для каждого входного признака. Если полученный набор нечетких множеств не фигурирует в качестве предпосылки имеющихся нечетких правил, то этот набор становится предпосылкой для нового правила. На втором этапе определяется следствие для каждой предпосылки и создание набора правил завершается.

Для описания алгоритма обучения, реализующего предложенный метод, введем следующие обозначения:

L – обучающее множество размерности s , где $(p, t) \in L$ является элементом множества и состоит из входного вектора числовых значений признаков $p \in R^n$ и метки t принадлежности к одному из классов C_1, \dots, C_m ;

$R_j = (A, C)$ – нечеткое правило классификации с предпосылкой A и следствием C , где $A = (\mu_j^1, \dots, \mu_j^n)$, а C определяет метку класса;

$R_j(p)$ – степень активации правила R_j , рассчитываемая как $R_j(p) = \min_{1 \leq i \leq n} (\mu_j^i(p_i))$;

μ_j^i – j -е нечеткое множество нечеткого разбиения входного признака x_i , имеется q_i нечетких множеств для признака x_i ;

c_A – вектор из m компонент, представляющий собой степень принадлежности к каждому классу для всех элементов обучающего множества предпосылки A ; c_A^i – i -я компонента c_A ;

$P_R \in [-1, 1]$ – значение коэффициента эффективности правила R ,

$$P_R = \frac{1}{S} \sum_{(p,t) \in L} (-1)^k R(p), \quad k = \begin{cases} 0, & \text{если } t \in C_j \\ 1 & \text{иначе} \end{cases} \quad (2)$$

Опишем алгоритм создания некоторого заданного количества k_{\max} нечетких правил вывода на основе обучающих данных:

1) выбрать элемент обучающего множества (p, t) из L ;

2) для каждого входного признака найти функцию принадлежности $\mu_{j_i}^{(i)}$, такую, что

$$\mu_{j_i}^{(i)}(p_i) = \max_{j \in \{1, \dots, q_i\}} \{\mu_j^{(i)}(p_i)\}; \quad (3)$$

3) если количество уже созданных правил меньше k_{\max} и не существует правила с предпосылкой вида

$$A = (\mu_{j_1}^{(1)}, \dots, \mu_{j_n}^{(n)}), \quad (4)$$

то создать нейрон ННМ для нового правила и соединить его с выходным узлом соответствующего класса, определяемого меткой t ;

4) если имеются нерассмотренные элементы обучающего множества и количество правил $k < k_{\max}$, то перейти к п. 1;

5) для каждого созданного правила с предпосылкой A рассчитать значения вектора c_A и определить класс с меткой t_j в качестве следствия

$$j = \arg \max_{i \in \{1, \dots, m\}} \{c_A^i\};$$

6) для каждого правила рассчитать значения коэффициента эффективности P_R ;

7) определить выходной набор правил с использованием одной из следующих процедур: простого обучения – в наборе правил сохраняются все созданные k_{\max} правил; выбора наилучшего – на основе рассчитанных коэффициентов эффективности P_R (см. выражение (2)) отбираются наилучшие правила. В этом случае возможен вариант, когда некоторые классы не представлены в наборе правил, если эти правила имеют низкие коэффициенты эффективности;

выбора наилучшего для класса – для каждого из m классов отбираются наилучшие правила. В результате каждый класс представлен равным числом правил.

При создании правила для каждой предпосылки в качестве следствия выбирается такой класс, который аккумулирует наибольшее значение вектора c_A предпосылки. Коэффициент эффективности $P_R \in [-1, 1]$ рассчитывается для каждого правила, причем при $P_R = 1$ правило классифицирует все обучающие данные правильно. Для $P_R = -1$ правило классифицирует все обучающие данные неправильно, тогда как для $P_R = 0$ количество правильных и неправильных классификаций примерно равно. Таким образом, при формировании набора классифицирующих правил рассматриваются правила с $P_R > 0$.

3. Обучение параметров нечеткой нейросетевой модели

В предложенной ННМ в качестве функций активации нейронов используются недифференцируемые функции минимум и максимум, поэтому невозможно напрямую использовать алгоритм обратного распространения ошибки для обучения параметров модели, каковыми являются параметры функций принадлежности, т. е. веса соединений входного и скрытого слоев ННМ. Поэтому был разработан эвристический алгоритм обучения параметров ННМ, который основан на обратном распространении ошибки классификации каждого элемента обучающего множества. Общая ошибка ННМ задается формулой

$$e = \frac{1}{2} \sum_{i=1}^n E_i = \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^m (t_{ij} - y_{ij})^2, \quad (5)$$

где m – количество классов или нейронов последнего слоя ННМ; n – количество входных векторов; t_{ij} и y_{ij} – желаемый и действительный выходы ННМ для входного вектора числовых признаков p_i .

Алгоритм использует ограничения, гарантирующие различимость функций принадлежности ННМ и обеспечивающие интерпретируемость получаемой нечеткой модели. Основная идея эвристического алгоритма заключается в определении степени влияния нечеткого правила или нейрона скрытого слоя на общий выход ННМ. Полученная информация затем используется для настройки параметров функций принадлежности – весовых коэффициентов ННМ.

После определения активаций элементов скрытого и выходного слоев ННМ для входного вектора признаков p рассчитывается выходная ошибка, которая распространяется по ННМ в обратном направлении для определения значения ошибки каждого из правил. Величина ошибки правила R_j зависит как от ошибки выходного нейрона соответствующего следствию правила, так и от текущей степени активации правила $R_j(p)$ и определяется как

$$E_{R_j} = (R_j(p) * (1 - R_j(p)) + \varepsilon) * E_{\text{следствие}(R_j)}, \quad (6)$$

где ε – малое положительное число, например $\varepsilon = 0,01$; $E_{\text{следствие}(R_j)}$ – ошибка выходного нейрона класса, соответствующего следствию правила R_j .

Алгоритм для настройки функций принадлежности предпосылок классифицирующего правила является эвристическим и состоит в следующем: если степень активации правила должна быть увеличена, носитель нечеткого множества расширяется и смещается по направлению к текущему входному значению обучающего элемента. Если же степень принадлежности должна быть уменьшена, осуществляется обратное преобразование: носитель сжимается и смещается в направлении, обратном текущему значению обучающего элемента (рис. 2).

Краткое описание алгоритма:

цикл размерности обучающего множества данных
 {
 для всех объектов $(p, t) \in L$ выполнить
 {

передать следующий обучающий объект (p, t) ;

для всех выходных признаков $y_j, j=1, \dots, m$

рассчитать ошибку выхода E_j (на основе $t_j - y_j$);

для каждого правила R_r с $R_r(p) > 0$ выполнить

{
определить метку j класса для следствия правила R_r ;
рассчитать ошибку правила E_{R_r} согласно выражению (6);

определить функцию принадлежности для модификации

$$j = \arg \min_{i \in \{1, \dots, n\}} \{\mu_r^{(i)}(p_i)\};$$

рассчитать модификацию параметров $(\mu_r^{(j)}, E_{R_r}, p_i)$

(в случае треугольной функции принадлежности, a_μ, b_μ и c_μ – параметры):

$$\delta_b = \sigma \cdot E_{R_r} \cdot (c_\mu - a_\mu) \cdot \text{sgn}(p_i - b_\mu),$$

$$\delta_a = -\sigma \cdot E_{R_r} \cdot (c_\mu - a_\mu) + \delta_b,$$

$$\delta_c = \sigma \cdot E_{R_r} \cdot (c_\mu - a_\mu) + \delta_b;$$

если режим *on-line* – выполнить модификацию $\mu_r^{(j)}$, учитывая ограничения;

}}

если режим пакетный, то для всех признаков p_i и для всех нечетких множеств $\mu_j^{(i)}, j=1, q_i$, выполнить модификацию.

}




Рис. 2. Изменение функции принадлежности для предпосылки правила

4. Оптимизация структуры нечеткой нейросетевой модели

Оптимизация структуры ННМ представляет собой удаление избыточных правил и нечетких множеств без нарушения общей точности классификации. Для оптимизации структуры используются четыре эвристические процедуры удаления:

избыточных признаков – входной признак, который имеет наименьшее влияние на выходной признак, удаляется; для определения этого признака используется статистическая мера корреляции или хи-квадрат-тест;

избыточных правил – правило, которое дает наименьшую суммарную степень активации, удаляется;

элементов предпосылки правила – удаляется нечеткое множество, дающее минимальную степень принадлежности в активном правиле для наименьшего числа обучающих данных; предполагается использование функции минимума в качестве оператора t -норм, в других случаях применение этого подхода менее эффективно;

нечетких множеств – определяется нечеткое множество с наибольшим носителем (шириной) и все элементы предпосылок правил, которые используют это нечеткое множество, удаляются. Предполагается, что нечеткое множество с большим носителем определяет большую степень принадлежности для многих входных векторов и, таким образом, элементы предпосылок, использующие это нечеткое множество, не влияют на расчет степени активации правила.

Описанные процедуры реализованы в виде алгоритмов, которые применяются итерационно. После каждого шага параметры ННМ обучаются с использованием описанного в разд. 3 алгоритма. Если общая ошибка классификации ННМ (см. выражение (5)) увеличивается, то набор нечетких правил возвращается в предыдущее состояние. Таким образом, модификации структуры ННМ сохраняются только в том случае, если точность классификации ННМ улучшается или остается без изменений. В процессе удаления элементов предпосылок, признаков или нечетких множеств набор правил ННМ может стать противоречивым. Это проблема разрешается путем удаления противоречивых и избыточных правил после каждого шага оптимизации. Противоречия возникают, если имеется два правила с различными следствиями, предпосылки которых либо совпадают, либо одна из них является более общей. Предпосылка A является более общей, чем предпосылка B , если A содержит меньше элементов предпосылки, чем B , и все нечеткие множества из A содержатся в B . Набор правил избыточен, если имеется два правила с идентичными следствиями и предпосылка одного из правил является более общей, чем предпосылка другого правила.

5. Результаты моделирования

Продемонстрируем использование ННМ для извлечения нечетких классифицирующих правил. В качестве тестового используется набор данных по раку груди из архива данных по машинному обучению. Набор данных состоит из 699 объектов, каждый объект представлен девятью признаками из диапазона $\{1, 2, \dots, 10\}$ и относится к одному из двух классов. Для оценки ошибки классификации построенной ННМ используется метод перекрестной проверки. Для перекрестной проверки множество объектов данных разбивается на несколько групп (в нашем случае десять), затем последовательно девять из десяти групп используются для построения ННМ, а десятая группа – для тестирования полученного классификатора. Таким образом, вероятность безошибочной классификации рассчитывается как среднее значение для десяти тестовых групп. Область значений для каждого числового признака разбивается на два нечетких множества, которые помечаются лингвистическими терминами «малое» и «большое». ННМ строится в три этапа. На первом этапе определяются все возможные нечеткие правила на основе данных и для каждого из двух классов отбираются три правила с наибольшим коэффициентом эффективности. Эти правила изначально покрывают только около 80 % данных, однако на втором этапе обучения параметров ННМ ситуация исправляется за счет последовательных сдвигов функций принадлежности нечетких множеств в направлении непокрытых входных данных. После этого (на третьем этапе) выполняется оптимизация структуры и количества правил ННМ, и в большинстве из десяти построений из структуры ННМ извлекается набор из двух следующих правил:

Правило R_1 : если p_1 (единообразие размера клетки) \in малое и p_6 (голое ядро) \in малое – класс 1 (доброкачественная опухоль).

Правило R₂: если p_1 (единообразие размера клетки) \in *большое* и p_3 (единообразие формы клетки) \in *большое* и p_6 (голое ядро) \in *малое* – **класс 2** (злокачественная опухоль).

Значение среднеквадратичной ошибки классификатора, построенного на всем множестве данных, равняется 64,15, а количество неправильно классифицированных случаев – 25 (96,3 % безошибочной классификации). В результате перекрестной проверки оценка вероятности безошибочной классификации $96,7 \% \pm 1,3 \%$. Набор правил построенной и обученной ННМ состоит всего из двух правил и прост в понимании. Вероятность безошибочной классификации достаточно большая, что говорит об эффективности построенной модели. Эффективность ННМ сравнима с результатами, полученными с применением дискриминантного анализа и многослойного персептрона для решения данной задачи, однако построенные с помощью этих методов модели не представляют полученные знания в явном виде и трудны для понимания конечными пользователями.

Заключение

Сочетание возможностей нейронных сетей и нечеткой логики позволяет создавать гибридные модели классификации, которые способны использовать имеющиеся данные и знания экспертов для определения начальной структуры и обучения параметров модели. Такие модели позволяют получать решения задачи классификации в виде набора интерпретируемых и понятных для пользователя правил. Описанная в работе гибридная нечеткая нейросетевая модель классификации представлена в виде трехслойной нейронной сети, реализующей процесс нечеткого логического вывода, причем входами и выходами данной сети являются четкие числовые данные. Такое представление ННМ облегчает понимание процесса прохождения входного набора признаков в системе нечеткого логического вывода и одновременно позволяет применить алгоритм обучения параметров нечеткого классификатора на основе имеющихся данных с использованием модифицированного нейросетевого алгоритма. Эвристические алгоритмы оптимизации структуры ННМ позволяют получить компактное и легко интерпретируемое решение классификационной задачи с сохранением достаточно высокого уровня вероятности безошибочной классификации данных. Дальнейшим направлением исследований в области нечеткого нейросетевого моделирования является использование генетических алгоритмов как средства оптимизации структуры ННМ на заключительном этапе ее построения. Можно предположить, что применение генетического алгоритма позволит найти глобальное решение классификационной задачи или получить парето-оптимальный набор решений [9].

Список литературы

1. Takagi, T. Fuzzy identification of systems and its applications to modeling and control / T. Takagi, M. Sugeno // IEEE Tran. Syst., Man, Cybern. – V. SMC 15. – 1985. – P. 116–132.
2. Nauck, D.D. Fuzzy data analysis with NEFCL SS / D.D. Nauck // Int. Journal of Approx. Reasoning. – Vol. 32. – 2003. – P. 103–130.
3. Zimmermann, H.J. Fuzzy Set Theory and its Applications / H.J. Zimmermann. – Boston, Dordrecht, Lancaster: Kluwer Academic Publishers, 1996.
4. Roger Jang, J.S. ANFIS – Adaptive-network-based fuzzy inference systems / J.S. Roger Jang // IEEE Trans. On Neural Networks. – Vol. 3, № 5. – 1992. – P. 714–723.
5. Ishibuchi, H. Three-objective genetics-based machine learning for linguistic rule extraction / H. Ishibuchi, T. Nakashima, T. Murata // Information Sciences. – V. 136. – 2001. – P. 109–133.
6. Abonyi, J. Data-driven generation of compact, accurate, and linguistically-sound fuzzy classifiers based on a decision-tree initialization / J. Abonyi, J. Roubos, F. Szeifert // International Journal of Approximate Reasoning. – Vol. 32, № 1. – 2003. – P. 1–21.
7. Roubos, J.A.. Learning fuzzy classifications rules from labeled data / J.A. Roubos, M. Setnes, J. Abonyi // Information Sciences. – Vol. 150. – 2003. – P.77–93.
8. Wang, L.X. Generating Fuzzy Rules by Learning from Examples / L.X. Wang, J.M. Mendel // IEEE Trans. on Systems, Man, and Cybernetics. – Vol. 22. – 1992. – P. 1414–1427.

9. Wang, H. Multi-objective hierarchical genetic algorithm for interpretable fuzzy rule-based knowledge extraction / H. Wang, S. Kwong, Y. Jin // Fuzzy Sets and systems. – Vol. 149. – 2005. – P. 149–186.

Поступила 24.03.06

*Объединенный институт проблем
информатики НАН Беларуси,
Минск, Сурганова, 6
e-mail: novosel@newman.bas-net.by*

N.A. Novoselova

DEVELOPMENT OF THE NEURO-FUZZY MODEL FOR CLASSIFICATION TASKS

Development of the neuro-fuzzy classification model (NFM) on the basis of numerical feature values is presented. Integration of neural networks and fuzzy systems allows to create hybrid models, which are capable to learn from data by minimizing an appropriate error function and to present the extracted knowledge in the form of linguistic classification rules. In order to develop the NFC with high interpretability properties along with sufficient classification accuracy it is proposed to use a three-stage approach to the generation of a fuzzy classification rule set, which presents the knowledge in the explicit and compact form.