

УДК 004.891.3

МАТЕМАТИЧЕСКОЕ ОБЕСПЕЧЕНИЕ И ПРОГРАММНЫЙ КОМПЛЕКС ФОРМИРОВАНИЯ НЕЧЕТКО-ПРОДУКЦИОННЫХ БАЗ ЗНАНИЙ ДЛЯ ЭКСПЕРТНЫХ ДИАГНОСТИЧЕСКИХ СИСТЕМ

Катасёв А.С.

*ФГБОУ ВПО «Казанский национальный исследовательский технический университет
им. А.Н. Туполева-КАИ», Казань, e-mail: Kat_726@mail.ru*

В данной работе решается задача автоматизации формирования баз знаний экспертных систем, предназначенных для диагностики состояния сложных объектов. Описывается разработанное математическое обеспечение. Предлагаются методики группировки параметров объекта диагностики и построения совокупности систем нечетко-продукционных правил. Указывается, что построенная совокупность систем правил является параметрической нечетко-продукционной моделью состояния объекта, параметрами которой являются функции принадлежности, веса условий и достоверность каждого правила. Для идентификации значений параметров модели предлагается специально разработанная нечеткая нейронная сеть. В процессе ее обучения производится параметрическая адаптация модели к имеющимся данным. Результатом обучения нечеткой нейронной сети является сформированная база знаний экспертной системы как совокупность систем нечетко-продукционных правил с идентифицированными значениями параметров. Разработанный программный комплекс, в основу которого заложены предложенные методики, модели и алгоритмы, позволяет автоматизировать все этапы интеллектуального анализа данных. Для оценки эффективности разработанного математического обеспечения выполнены исследования по аппроксимации зависимостей в известных наборах данных. Эксперименты показали, что получаемые системы правил обладают высокой классифицирующей способностью, что указывает на возможность эффективного использования программного комплекса для формирования баз знаний экспертных диагностических систем.

Ключевые слова: сложный объект, интеллектуальный анализ данных, нечетко-продукционное правило, нечеткая нейронная сеть, база знаний, экспертная система, диагностика

MATHEMATICAL AND SOFTWARE FOR FUZZY-PRODUCTIONS KNOWLEDGE BASES GENERATION OF THE EXPERT DIAGNOSTIC SYSTEMS

Katasev A.S.

Kazan State Technical University n.a. A.N. Tupolev, Kazan, e-mail: Kat_726@mail.ru

In this paper solves the problem of automating the knowledge bases generation of expert diagnostic systems. Describes the developed mathematical and software. The techniques of grouping object parameter diagnostics and constructing of a set of fuzzy production rules are offered. Constructed a systems of rules is a parametric fuzzy-production model of an object state. The parameters of the model are membership functions, weights conditions and certainty factors of each rule. For identify the parameters of the model are specially designed fuzzy neural network. In the process of learning is performed parametric adaptation of the model to the data. The result of learning fuzzy neural network is generated by a knowledge base of the expert system as sets of fuzzy production rules with the identified parameter values. Developed software based on methods, models and algorithms allows to automate all phases of the data mining. To evaluate the efficiency of the developed mathematical software conducted researches on approximation of the dependencies in the known data sets. The experiments showed that the resulting sets of rules for classifying the ability to have a high. Thus developed mathematical and software can be used effectively to generate knowledge bases of expert diagnostic systems.

Keywords: complex object, data mining, fuzzy production rule, fuzzy neural network, knowledge base, expert system, diagnostics

В настоящее время для решения большого количества практических задач в различных предметных областях человеческой деятельности широкое применение получили экспертные системы. Их появление обусловлено необходимостью тиражирования знаний экспертов в связи с возрастанием числа сложных объектов и систем, при работе с которыми знания и квалификации обычных специалистов становится недостаточной.

Для описания сложного объекта, как правило, приходится оперировать данными, обладающими следующими особенностями: большой объем, разнотипность, наличие нечеткости в данных, отсутствие части исходных данных, большое количество

параметров. Достоинством экспертных систем является возможность их эффективного применения при решении практических задач в указанных условиях. Среди всех классов экспертных систем особое место занимают диагностические системы ввиду важности решения данной задачи в широком диапазоне областей: экономическая, медицинская, техническая диагностика и др.

При построении экспертной системы перед ее разработчиками встанут проблемы добычи и формализации знаний. Существует два основных способа получения знаний [2]: ручной и автоматизированный. В первом случае правила формулируются экспертом, что требует от него большой аналитической работы. Во втором случае

используются различные инструментальные средства формирования правил на основе алгоритмов интеллектуального анализа данных. Данный подход к получению знаний является актуальным и может быть использован при формировании баз знаний экспертных диагностических систем. Практическая реализация данной задачи требует решения вопросов выбора модели представления знаний, для диагностики состояния сложного объекта, с учетом особенностей исходных данных, а также разработки методов, моделей и алгоритмов анализа данных с целью построения модели диагностики выбранного вида.

Методика группировки параметров объекта диагностики

База знаний экспертной системы представляет собой совокупность правил, описывающих закономерности моделируемого объекта. При большом числе параметров объекта формирование базы знаний начинается с этапа группировки параметров, где каждая группа определяет закономерности «вход» – «выход» для подсистемы сложного объекта.

Рассмотрим постановку задачи разработки методики группировки параметров. Пусть дано множество параметров $P = \{p_1, p_2, \dots, p_k, \dots, p_N\}$, описывающих объект диагностики, множество диагнозов состояния объекта, а также множество целевых параметров $P_{out} = \{p_{out_1}, p_{out_2}, \dots, p_{out_j}, \dots, p_{out_m}\} \subset P$, $m < Nm < N$, где все $p_{out_j}, j = \overline{1, m}$ принимают конечное дискретное множество значений (состояний объекта). Необходимо сформировать группы параметров $G_j = \{P_j^{in}, p_{out_j}\}, j = \overline{1, m}$, где $P_j^{in} \subset P$ – множество входных параметров для каждого из целевого параметра $p_{out_j} \notin P_j^{in}$, значимо влияющих на него.

Методика группировки параметров состоит из следующих основных этапов.

1. Эксперт на основе своих знаний и анализа имеющихся данных формирует множество диагнозов состояния исследуемого объекта.

2. Среди всего множества параметров $\{p_1, p_2, \dots, p_k, \dots, p_N\}$ выбираются целевые параметры $\{p_{out_1}, p_{out_2}, \dots, p_{out_j}, \dots, p_{out_m}\}$, значения которых связаны с диагнозами.

3. Для каждого из целевых параметров p_{out_j} эксперт, основываясь на результатах анализа корреляций между всеми параметрами p_k и p_{out_j} , выбирает множество неза-

висимых входных параметров P_j^{in} , значимо влияющих на целевой.

4. Формируется множество групп параметров «вход–выход» $G_j = \{P_j^{in}, p_{out_j}\}, j = \overline{1, m}$.

Для реализации предложенной методики необходимо наличие таблицы исходных данных. При этом каждая сформированная группа параметров описывает подсистему сложного объекта, что значительно упрощает его описание.

Модель представления знаний в экспертной системе

Для представления знаний в экспертной диагностической системе и описания зависимостей в сформированных группах параметров предлагается использовать нечетко-продукционную модель следующего вида [3]:

$$\text{ЕСЛИ } x_1 = \vec{A}_1(w_1) \text{ И } x_2 = \vec{A}_2(w_2)$$

$$\text{И } \dots x_n = \vec{A}_n(w_n) \text{ ТО } y = B[CF], \quad (1)$$

где x_i – входные переменные; $w_i \in [0, 1]$ – веса условий “ $x_i = \vec{A}_i$ ”; $\vec{A}_i = \{A_i, \tilde{A}_i\}$, A_i – четкое значение входа; $\tilde{A}_i = \{x_i, \mu_{\tilde{A}_i}(x_i)\}$ – нечеткое значение входа; $\mu_{\tilde{A}_i}(x_i)$ – функция принадлежности; y – выходная переменная; B – четкое значение выхода, $CF \in [0, 1]$ – достоверность правила.

Особенность модели представления знаний вида (1) заключается в одновременном выполнении следующих требований:

- возможность использования разнотипных входных и выходных параметров;
- возможность обработки четких и нечетких входных данных;
- учет значимости (весов) условий в правиле;
- учет значимости (достоверности) каждого правила.

В рамках нечетко-продукционных правил вида (1) возможно описание зависимостей, характеризующих состояние объектов, в различных предметных областях.

Методика построения совокупности систем правил

Следующим этапом формирования базы знаний является построение совокупности систем нечетко-продукционных правил $S_{R_j}, j = \overline{1, m}$, каждая из которых определяется группами параметров $G_j = \{P_j^{in}, p_{out_j}\}, j = \overline{1, m}$, а также градациями (значениями) входных и целевого

параметра группы. Разработанная методика построения совокупности систем правил состоит из трех основных шагов.

1. Для каждого параметра $p_k \in G_j$ определяется $g_k = \{\hat{g}_k, \tilde{g}_k\}$, где \hat{g}_k – число значений четкого параметра p_k , а \tilde{g}_k – число градаций нечеткого параметра.

$$S_{R_1} : \begin{cases} \text{ЕСЛИ } p_1 = \tilde{A}_1^1(w_1^1) \text{ И... } p_{13} = \tilde{A}_1^{13}(w_1^{13}) \text{ ТО } p_5 = A_1^5 [CF_1^1] \\ \dots \\ \text{ЕСЛИ } p_1 = \tilde{A}_{g_1}^1(w_{g_1}^1) \text{ И... } p_{13} = \tilde{A}_{g_{13}}^{13}(w_{13}^{13}) \text{ ТО } p_5 = A_{g_1}^5 [CF_{N_{R_1}}^1] \\ \dots \\ \dots \\ S_{R_m} : \begin{cases} \text{ЕСЛИ } p_4 = \tilde{A}_1^4(w_1^4) \text{ И... } p_{23} = \tilde{A}_1^{23}(w_1^{23}) \text{ ТО } p_{20} = A_1^{20} [CF_1^m] \\ \dots \\ \text{ЕСЛИ } p_4 = \tilde{A}_{g_4}^4(w_{g_4}^4) \text{ И... } p_{23} = \tilde{A}_{g_{23}}^{23}(w_{23}^{23}) \text{ ТО } p_{20} = A_{g_{20}}^{20} [CF_{N_{R_m}}^1] \end{cases} \end{cases}$$

где S_{R_j} – система правил, описывающих группу параметров G_j ; g_k – число значений

(градаций) параметра p_k , $N_{R_j} = \prod_{k: p_k \in G_j} g_k$ –

число правил в системе S_{R_j} , $j = \overline{1, m}$.

Построенная совокупность систем правил вида (1) представляет параметрическую нечетко-продукционную модель состояния объекта. Параметрами модели являются функции принадлежности $\mu_{\tilde{A}_i}(x_i)$ в правилах, достоверность каждого правила CF , а также веса условий w_i в правилах. Применение систем правил для определения состояния объекта основано на использовании специально разработанного алгоритма логического вывода.

Алгоритм логического вывода на системах правил

Для понимания организации логического вывода на системах нечетко-продукционных правил вида (1) введем следующие обозначения:

• $R \in [0, 1]$ (*response*) – степень срабатывания условной части правила:

$$R = \min(\mu_{\tilde{A}_i}(p_i^*), i: p_i^* \neq \emptyset)$$

где p_i^* , $i = \overline{1, n}$ – четкие значения n входных параметров правила; $\mu_{\tilde{A}_i}(p_i^*)$ – степени принадлежности входных значений p_i^* к \tilde{A}_i ;

2. Строится множество всех комбинаций из значений входных и целевого параметров.

3. Для каждой комбинации задается правило в виде (1).

Рассмотрим пример совокупности систем нечетко-продукционных правил вида (1).

• $T \in [0, 1]$ (*trust*) – совокупный вес условной части правила:

$$T = \frac{\sum_{kn=1}^{n_{kn}} w_{kn}}{\sum_{i=1}^n w_i}$$

где w_i , $i = \overline{1, n}$ – веса всех ограничений \tilde{A}_i на параметры в правиле, w_{kn} , $kn = \overline{1, n_{kn}}$ – веса ограничений, значения которых известны (определены);

• $C \in [0, 1]$ (*complex*) – комплексная оценка достоверности правила: $C = R * T * CF$, где $CF \in [0, 1]$ (*certainty factor*) – достоверность правила.

Для каждой системы правил S_{R_j} , описывающей группу параметров $G_j = \{P_j^{in}, P_{out_j}\}$, используется алгоритм логического вывода, состоящий из следующих шагов.

1. Ввод значений P_i^* входных параметров P_j^{in} группы G_j .

2. Для каждого правила $Rule_r$ системы S_{R_j} расчет степени срабатывания условий R_r .

3. Формирование конфликтного множества, включающего правила с ненулевой степенью срабатывания:

$$S_{conf} = \{Rule_r | R_r \neq 0\}, r = \overline{1, N_{R_j}}$$

4. Для всех правил из конфликтного множества $Rule_r \in S_{conf}$ расчет совокупного веса условной части правила T_r , а также комплексной оценки C_r .

5. Разрешение конфликта – выбор правила с максимальной комплексной оценкой достоверности решения правила:

$$Rule_r^* : \max_{r: Rule_r \in S_{conf}} C_r.$$

6. Получение значения $P_{out_j}^*$ выходного параметра P_{out_j} выбранного правила $Rule_r^*$ в качестве искомого состояния объекта.

Предложенный алгоритм позволяет определять состояние сложного объекта.

Параметрическая адаптация модели состояния объекта

Для практического применения алгоритма логического вывода требуется, чтобы параметры нечетко-продукционной модели

состояния объекта были определены. Для этого необходимо произвести ее параметрическую адаптацию к имеющимся данным [4] – определить значения параметров, при которых минимизируется ошибка – отношение числа N_{false} неправильно оцененных состояний объекта к общему объему N исходных данных:

$$E(Y) = \frac{N_{false}}{N} \rightarrow \min_Y. \quad (2)$$

Для решения данной задачи используется специально разработанная нечеткая нейронная сеть, в процессе обучения которой определяются значения параметров модели состояния объекта. На рис. 1 приведен пример структуры сети.




Рис. 1. Пример структуры нечеткой нейронной сети

Архитектура нечеткой нейронной сети соответствует виду нечетко-продукционных правил, а также описанному алгоритму логического вывода на них. Обучение сети основано на использовании метода градиентного спуска.

Таким образом, реализация этапов группировки параметров объекта, построения совокупности систем правил и параметрической адаптации модели к имеющимся данным позволяет сформировать базу знаний как совокупность систем нечетко-продукционных правил с идентифицированными значениями параметров.

Программный комплекс автоматизирует формирование базы знаний

Для автоматизации всех этапов интеллектуального анализа исходных данных и формирования баз знаний экспертных диагностических систем разработан программный комплекс, в основу которого положены описанные методики, модели и ал-

горитмы. На рис. 2 представлена структура программного комплекса.

Комплекс состоит из четырех модулей, соответствующих этапам формирования базы знаний. Для разработки программного комплекса был выбран высокоуровневый объектно-ориентированный кроссплатформенный язык программирования Java. При реализации комплекса использовалась свободная интегрированная среда разработки NetBeans IDE.

Проведение исследований на базе программного комплекса

С целью определения классифицирующей способности формируемых баз знаний произведено решение известных задач классификации из общедоступного источника UCI Machine Learning Repository [5]. В табл. 1 представлена информация о характеристиках наборов исходных данных, соответствующих решаемым задачам.

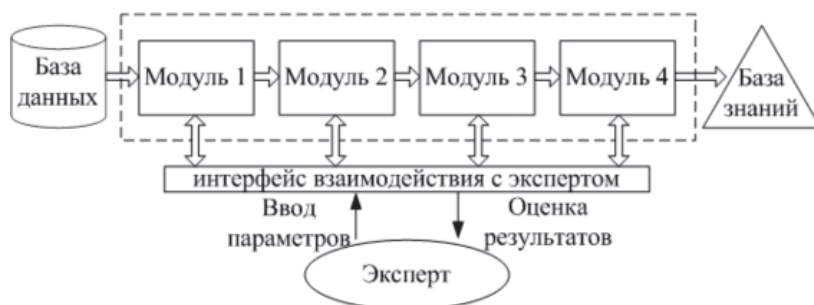


Рис. 2. Структура программного комплекса

Таблица 1

Характеристика исходных данных

| Набор исходных данных | Число входных параметров | Типы входных параметров | Объем выборки | Число классов |
|----------------------------|--------------------------|--------------------------|---------------|---------------|
| BUPA Liver Disorders | 6 | числовые | 345 | 2 |
| Australian Credit Approval | 14 | числовые, категориальные | 690 | 2 |
| German Credit Data | 20 | числовые, категориальные | 1000 | 2 |

В первом наборе представлены данные, соответствующие задаче диагностирования заболевания печени человека по результатам анализа его крови. Второй набор данных соответствует задаче выявления подозрительных транзакций с банковскими картами. Третий набор данных соответствует задаче принятия решения о выдаче по-

требительского кредита на основании анкетных данных заемщика.

В качестве меры эффективности баз знаний выступала точность классификации. Для определения значимости получаемых результатов производилось их сравнение с известными результатами других авторов [1]. В табл. 2 приведены результаты классификации.

Таблица 2

Сравнение точности методов классификации

| Метод классификации | Наборы данных | BUPA Liver Disorders | Australian Credit Approval | German Credit Data |
|-----------------------------------|---------------|----------------------|----------------------------|--------------------|
| Байесовский классификатор | | 0,629 | 0,847 | 0,679 |
| Многослойный перцептрон | | 0,693 | 0,833 | 0,716 |
| Метод случайных подпространств | | 0,632 | 0,852 | 0,677 |
| Коллектив нейронных сетей | | 0,783 | 0,918 | 0,815 |
| Нечетко-продукционная база знаний | | 0,762 | 0,859 | 0,827 |

Из таблицы видно, что классифицирующая способность сформированных нечетко-продукционных баз знаний уступает лишь классификатору на основе коллектива нейронных сетей и превосходит все известные методы классификации, участвующие в сравнении. Полученные результаты указывают на возможность эффективного использования предложенного подхода к формированию баз знаний экспертных диагностических систем.

Заключение

Описанные в работе математическое обеспечение и программный комплекс позволяют формировать базы знаний экспертных диагностических систем. Проверка

работы программного комплекса на известных наборах данных показала высокую эффективность разработанного математического обеспечения и практическую пригодность программного комплекса к решению поставленных задач.

В перспективе, с целью обобщения результатов проведенного исследования и развития данного научного направления, видится решение задач, связанных с совершенствованием математического аппарата и доработкой программного комплекса до уровня аналитической платформы с широкими возможностями по формированию баз знаний промышленных экспертных систем диагностики состояния сложных объектов.

Список литературы

1. Бухтояров В.В. Трехступенчатый эволюционный метод формирования коллективов нейронных сетей для решения задач классификации // Программные продукты и системы. – 2012. – № 4. – С. 101–106.

2. Гаврилова Т.А., Хорошевский В.Ф. Базы знаний интеллектуальных систем. – СПб.: Питер, 2001. – 384 с.: ил.

3. Глова В.И., Аникин И.В., Шагиахметов М.Р. Методы многокритериального принятия решений в условиях неопределенности в задачах нефтедобычи. Препринт 04П2. – Казань: Изд-во Казан. гос. техн. ун-та, 2004. – 31 с.

4. Ротштейн А.П. Интеллектуальные технологии идентификации: нечеткая логика, генетические алгоритмы, нейронные сети. – Винница: УНИВЕРСУМ-Винница, 1999. – 320 с.

5. Bache K., Lichman M. UCI Machine Learning Repository [available at: <http://archive.ics.uci.edu/ml>]. Irvine, CA: University of California, School of Information and Computer Science, 2013.

References

1. Buhtojarov V.V. *Programmnye produkty i sistemy*, 2012, no. 4, pp. 101–106.

2. Gavrilova T.A., Horoshevskij V.F. *Bazy znaniy intellektualnyh sistem*. SPb., Piter, 2001, 384 p.

3. Glova V.I., Anikin I.V., Shagiahmetov M.R. *Metody mnogokriterialnogo prinjatija reshenij v uslovijah neopredelenosti v zadachah neftedobychi*. Preprint 04P2, Kazan, KSTU, 2004, 31 p.

4. Rotshtejn A.P. *Intellektualnye tehnologii identifikacii: nechetkaja logika, geneticheskie algoritmy, nejronnye seti*. Vinnica, UNIVERSUM-Vinnica, 1999, 320 p.

5. Bache K., Lichman M. UCI Machine Learning Repository [available at: <http://archive.ics.uci.edu/ml>]. Irvine, CA: University of California, School of Information and Computer Science, 2013.

Рецензенты:

Песошин В.А., д.т.н., профессор, заведующий кафедрой компьютерных систем Казанского национального исследовательского технического университета им. А.Н. Туполева-КАИ, г. Казань;

Исмагилов И.И., д.т.н., профессор, заведующий кафедрой статистики, эконометрики и естествознания Казанского (Приволжского) федерального университета, г. Казань.

Работа поступила в редакцию 17.10.2013.