

УДК: 004.94

## Нейронечеткая модель формирования нечетких правил для оценки состояния объектов в условиях неопределенности

А. С. Катасёв

Казанский национальный исследовательский технический университет им. А. Н. Туполева – КАИ,  
Россия, 420111, г. Казань, ул. К. Маркса, д. 10

E-mail: Kat\_726@mail.ru

*Получено 19.10.2018, после доработки — 02.05.2019.*

*Принято к публикации 30.05.2019.*

В данной статье решается задача построения нейронечеткой модели формирования нечетких правил и их использования для оценки состояния объектов в условиях неопределенности. Традиционные методы математической статистики или имитационного моделирования не позволяют строить адекватные модели объектов в указанных условиях. Поэтому в настоящее время решение многих задач основано на использовании технологий интеллектуального моделирования с применением методов нечеткой логики. Традиционный подход к построению нечетких систем связан с необходимостью привлечения эксперта для формулирования нечетких правил и задания используемых в них функций принадлежности. Для устранения этого недостатка актуальна автоматизация формирования нечетких правил на основе методов и алгоритмов машинного обучения. Одним из подходов к решению данной задачи является построение нечеткой нейронной сети и обучение ее на данных, характеризующих исследуемый объект. Реализация этого подхода потребовала выбора вида нечетких правил с учетом особенностей обрабатываемых данных. Кроме того, потребовалась разработка алгоритма логического вывода на правилах выбранного вида. Этапы алгоритма определяют число слоев в структуре нечеткой нейронной сети и их функциональность. Разработан алгоритм обучения нечеткой нейронной сети. После ее обучения производится формирование системы нечетко-продукционных правил. На базе разработанного математического обеспечения реализован программный комплекс. На его основе проведены исследования по оценке классифицирующей способности формируемых нечетких правил на примере анализа данных из UCI Machine Learning Repository. Результаты исследований показали, что классифицирующая способность сформированных нечетких правил не уступает по точности другим методам классификации. Кроме того, алгоритм логического вывода на нечетких правилах позволяет успешно производить классификацию при отсутствии части исходных данных. С целью апробации произведено формирование нечетких правил для решения задачи по оценке состояния водоводов в нефтяной отрасли. На основе исходных данных по 303 водоводам сформирована база из 342 нечетких правил. Их практическая апробация показала высокую эффективность в решении поставленной задачи.

Ключевые слова: нейронечеткая модель, нечеткая нейронная сеть, нечетко-продукционное правило, формирование базы знаний, оценка состояния объекта

Работа выполнена при финансовой поддержке Министерства образования и науки РФ в рамках государственного задания по проекту № 8.6141.2017/8.9.

© 2019 Алексей Сергеевич Катасёв

Статья доступна по лицензии Creative Commons Attribution-NoDerivs 3.0 Unported License.  
Чтобы получить текст лицензии, посетите веб-сайт <http://creativecommons.org/licenses/by-nd/3.0/>  
или отправьте письмо в Creative Commons, PO Box 1866, Mountain View, CA 94042, USA.

UDC: 004.94

## Neuro-fuzzy model of fuzzy rules formation for objects state evaluation in conditions of uncertainty

A. S. Katasev

Kazan National Research Technical University named after A. N. Tupolev,  
10 K. Marx st., Kazan, 420111, Russia

E-mail: Kat\_726@mail.ru

*Received 19.10.2018, after completion — 02.05.2019.*

*Accepted for publication 30.05.2019.*

This article solves the problem of constructing a neuro-fuzzy model of fuzzy rules formation and using them for objects state evaluation in conditions of uncertainty. Traditional mathematical statistics or simulation modeling methods do not allow building adequate models of objects in the specified conditions. Therefore, at present, the solution of many problems is based on the use of intelligent modeling technologies applying fuzzy logic methods. The traditional approach of fuzzy systems construction is associated with an expert attraction need to formulate fuzzy rules and specify the membership functions used in them. To eliminate this drawback, the automation of fuzzy rules formation, based on the machine learning methods and algorithms, is relevant. One of the approaches to solve this problem is to build a fuzzy neural network and train it on the data characterizing the object under study. This approach implementation required fuzzy rules type choice, taking into account the processed data specificity. In addition, it required logical inference algorithm development on the rules of the selected type. The algorithm steps determine the number and functionality of layers in the fuzzy neural network structure. The fuzzy neural network training algorithm developed. After network training the formation fuzzy-production rules system is carried out. Based on developed mathematical tool, a software package has been implemented. On its basis, studies to assess the classifying ability of the fuzzy rules being formed have been conducted using the data analysis example from the UCI Machine Learning Repository. The research results showed that the formed fuzzy rules classifying ability is not inferior in accuracy to other classification methods. In addition, the logic inference algorithm on fuzzy rules allows successful classification in the absence of a part of the initial data. In order to test, to solve the problem of assessing oil industry water lines state fuzzy rules were generated. Based on the 303 water lines initial data, the base of 342 fuzzy rules was formed. Their practical approbation has shown high efficiency in solving the problem.

Keywords: neuro-fuzzy model, fuzzy neural network, fuzzy production rule, knowledge base formation, object state evaluation

Citation: *Computer Research and Modeling*, 2019, vol. 11, no. 3, pp. 477–492 (Russian).

The work was supported by the Russian Federation Ministry of Education and Science, project No. 8.6141.2017/8.9.

© 2019 Alexey S. Katasev

This work is licensed under the Creative Commons Attribution-NoDerivs 3.0 Unported License.

To view a copy of this license, visit <http://creativecommons.org/licenses/by-nd/3.0/>

or send a letter to Creative Commons, PO Box 1866, Mountain View, CA 94042, USA.

## 1. Введение

В настоящее время в различных областях человеческой деятельности (таких как нефтяная отрасль, промышленность, медицина и др.) задачу математического моделирования для оценки (классификации, диагностики) состояния объектов часто приходится решать в условиях неопределенности, которая характеризуется неполнотой исходных данных, объективной неопределенностью (наличием шумов и выбросов в данных), а также лингвистической неопределенностью (субъективными оценками эксперта). Рассматриваемые объекты могут быть различной природы и представлять механические узлы и детали станков, водоводы на кустовых насосных станциях, электронные почтовые сообщения, функциональные системы человека и т. д. Задача оценки состояния конкретного объекта заключается в выборе его состояния (например, наличие спама, конкретный диагноз человека, вид неисправности оборудования и т. д.) из заданного множества, а также в вычислении степени достоверности полученной оценки.

Для обработки объективной неопределенности в исходных данных традиционно используются методы исключения выбросов и фильтрации шумов. Для учета лингвистической неопределенности и неполноты данных целесообразно использовать методы нечеткой логики и алгоритмы нечеткого логического вывода. Теория нечетких множеств [Zadeh, 1965], как одно из направлений искусственного интеллекта [Akhmetvaleev, Katasev, 2018; Ge et al., 2017; Guskov et al., 2018; Ismagilov et al., 2018], позволяет строить нечеткие модели объектов с использованием лингвистических переменных и механизмов логического вывода. При этом нечеткая модель представляет систему нечетко-продукционных правил и алгоритм вывода на правилах. В настоящее время так называемые модели нечеткого логического вывода используются при разработке нечетких экспертных систем, применяемых для решения задач диагностики, управления, поддержки принятия решений в различных предметных областях [Liu et al., 2017; Namestnikov et al., 2016; Tron, Margalio, 2004; Vaskovic et al., 2018].

В большинстве нечетких экспертных систем приходится привлекать экспертов для решения частных задач, связанных с построением функций принадлежности, определением их формы, заданием оптимального количества нечетких градаций для входных лингвистических переменных. Технологическая необходимость структурирования и формализации системы правил принятия решений на основе их вербального описания экспертом приводит к высокой трудоемкости формирования нечетких моделей. Кроме того, субъективный характер экспертных оценок, а также отсутствие информации о достоверности получаемых решений в случае неполноты исходных данных могут привести к неэффективности формируемых нечетких моделей, недостаточной точности получаемых оценок о состоянии объектов и, как следствие, низкой эффективности практического использования нечетких экспертных систем.

В настоящее время существуют адаптивные системы нечеткого логического вывода, в которых параметры функций принадлежности настраиваются автоматически (без участия экспертов) в процессе обучения на экспериментальных данных [Yarushkina, 2001]. В технической литературе класс адаптивных нечетких экспертных систем получил название «мягкие экспертные системы» [Hassan et al., 2017]. Мягкий подход к формированию нечетких правил основан на использовании методов и алгоритмов интеллектуального анализа данных [Rauch, 2019]. Однако существующие адаптивные системы являются узкоспециализированными и предназначены для получения нечетких правил в рамках традиционных моделей представления знаний (Мамдани, Сугено, Цукамото и др.), что не позволяет использовать реализованные в них методы и алгоритмы для формирования эффективных нечетких моделей оценки состояния объектов в условиях разнотипности, нечеткости, неполноты исходных данных. Поэтому для построения адекватных нечетких моделей оценки состояния объектов в условиях неопределенности актуальна разработка нового подхода к формированию нечетких правил, адекватно описывающих закономерности в анализируемых данных.

## 2. Разработка модели нечеткого логического вывода для оценки состояния объектов в условиях неопределенности

Процессы формирования нечетких правил связаны с вопросами интерпретации баз данных путем извлечения скрытых в них закономерностей. Для этого традиционно применяется технология обнаружения знаний в базах данных [Wachla, Moczulski, 2007]. Применение этой технологии для формирования нечетких правил оценки состояния объектов в условиях неопределенности включает этапы выборки исходных данных (характеризующихся возможной разнотипностью, нечеткостью, неполнотой), их предобработки (исключения выбросов и фильтрации шумов), трансформации, интеллектуального анализа и оценки. На этапе анализа данных необходимо формировать нечеткие правила, учитывающие особенности исходных данных.

Для построения нечеткой модели оценки состояния объектов в условиях неопределенности необходим анализ видов продукционных правил для удовлетворения требованиям:

- 1) возможность использования разнотипных входных переменных правила,
- 2) возможность обработки четких и нечетких входных данных,
- 3) учет значимости условий (весов) в правиле,
- 4) учет значимости каждого правила (достоверности).

Рассмотрим вид простого продукционного правила:

$$\text{ЕСЛИ } x_1 = A_1 \text{ И } x_2 = A_2 \text{ И } \dots x_n = A_n \text{ ТО } y = B \text{ [CF]}. \quad (1)$$

В моделях этих правил входные переменные  $x_1, x_2, \dots, x_n$  могут быть разнотипными (как числовыми, так и категориальными), но принимают только четкие значения типа  $x_i = A_i$  ( $i = 1..n$ ). При этом параметр  $CF \in [0, 1]$  определяет достоверность продукционного правила. Для обработки входных данных нечеткой природы используются различные модели нечетких продукций. Примером такой модели является правило вида

$$\text{ЕСЛИ } x_1 = \tilde{A}_1 \text{ И } x_2 = \tilde{A}_2 \text{ И } \dots x_n = \tilde{A}_n \text{ ТО } y = B. \quad (2)$$

Входные переменные правила являются числовыми и могут принимать как четкие, так и нечеткие значения. Для повышения гибкости нечетких продукций используются модифицированные нечетко-продукционные правила следующего вида:

$$\text{ЕСЛИ } x_1 = \tilde{A}_1(w_1) \text{ И } x_2 = \tilde{A}_2(w_2) \text{ И } \dots x_n = \tilde{A}_n(w_n) \text{ ТО } y = B \text{ [CF]}. \quad (3)$$

Использование весов условий  $w_i$  ( $i = 1..n$ ) в левой части правила позволяет учитывать неполноту исходных данных уменьшением значения оценки достоверности принимаемого решения с учетом веса условия с отсутствующим значением.

В таблице 1 приведены результаты сравнения рассмотренных видов правил.

Таблица 1. Сравнение видов традиционных продукционных правил

Критерии \ Вид правила	Использование разнотипных входных переменных	Обработка четких и нечетких входных данных	Учет значимости условий в правиле	Учет достоверности правила
Простое продукционное	да	нет	нет	да
Нечеткое продукционное	нет	да	нет	нет
Модифицированное нечеткое продукционное	нет	да	да	да

Ни один из видов правил (1)–(3) не удовлетворяет всем рассматриваемым критериям. Таким образом, необходимо модифицировать вид нечетко-продукционных правил для удовлетворения сформулированным выше требованиям 1–4, а также разработать алгоритм логического

вывода на системе нечетко-продукционных правил для оценки состояния объектов и расчета достоверности принимаемых решений при отсутствии части исходных данных с учетом значимости условий в правилах и достоверности правил.

Для оценки состояния объектов в условиях неопределенности предлагается следующий модифицированный вид нечетко-продукционных правил:

$$\text{ЕСЛИ } x_1 = \vec{A}_1(w_1) \text{ И } x_2 = \vec{A}_2(w_2) \text{ И } \dots x_n = \vec{A}_n(w_n) \text{ ТО } y = B [CF], \quad (4)$$

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 входной переменной,  $\tilde{A}_i = \{x_i, \mu_{\tilde{A}_i}(x_i)\}$  — нечеткое значение входной переменной,  $\mu_{\tilde{A}_i}(x_i)$  — функция принадлежности входных значений  $x_i$  к  $\tilde{A}_i$ ,  $y$  — выходная переменная,  $B$  — четкое значение выхода,  $CF \in [0, 1]$  — достоверность правила.

Отличием правил вида (4) от (3) является возможность использования разнотипных входных переменных, что достигается введением четких и нечетких ограничений  $\vec{A}_i$  ( $i = 1..n$ ) на значения переменных  $x_i$  в правилах.

Для оценки состояния объектов на основе правил вида (4) разработан алгоритм логического вывода. Введем следующие обозначения, используемые в работе алгоритма:

- $R \in [0, 1]$  — степень срабатывания условной части правила:

$$R = \min(\mu_{\tilde{A}_i}(x_i^*)), \quad (5)$$

где  $x_i^*$ ,  $i = \overline{1, n}$ , — известные четкие значения  $n$  входных переменных правила,  $\mu_{\tilde{A}_i}(x_i^*)$  — степени принадлежности входных значений  $x_i^*$  к  $\tilde{A}_i$ :

- для нечетких входных переменных  $\mu_{\tilde{A}_i}(x_i^*) \in [0, 1]$ ;
- для четких входных переменных  $\mu_{A_i}(x_i^*) = \begin{cases} 1, & \text{если } x_i^* = A_i, \\ 0, & \text{если } x_i^* \neq A_i; \end{cases}$
- если  $x_i^*$  отсутствует, то  $\mu_{\tilde{A}_i}(x_i^*)$  не вычисляется и не используется в (5);
- $T \in [0, 1]$  — нормированный совокупный вес условной части правила:

$$T = \frac{\sum_{kn=1}^{n_{kn}} w_{kn}}{\sum_{i=1}^n w_i}, \quad (6)$$

где  $w_i$ ,  $i = \overline{1, n}$ , — веса условий  $x_i = \vec{A}_i$  в правиле,  $w_{kn}$ ,  $kn = \overline{1, n_{kn}}$ , — веса условий с известными входными значениями;

- $C \in [0, 1]$  — комплексная оценка достоверности решения, полученного на основе правила:

$$C = R \cdot T \cdot CF, \quad (7)$$

где  $CF \in [0, 1]$  — достоверность правила.

Для выполнения логического вывода на правилах (4) разработан следующий алгоритм.

1. Ввод значений  $x_i^*$  входных переменных  $x_i$ ,  $i = \overline{1, n}$ .

2. Для каждого правила  $Rule_r$ ,  $r = \overline{1, N}$ , вычисление степени срабатывания его условий  $R_r$  по формуле (5).

3. Формирование конфликтного множества, включающего правила с ненулевой степенью срабатывания:  $S_{conf} = \{Rule_r \mid R_r \neq 0\}$ ,  $r = \overline{1, N}$ .

4. Для всех правил  $Rule_r \in S_{conf}$  расчет нормированного совокупного веса условной части правила  $T_r$  по формуле (6) и комплексной оценки  $C_r$  по формуле (7).

5. Разрешение конфликта — выбор правила с максимальной комплексной оценкой достоверности решения:  $Rule_r^* : \max_{r: Rule_r \in S_{conf}} C_r$ .

6. Определение состояния объекта  $B^*$  как значения выходной переменной  $y$  выбранного правила  $Rule_r^*$  и значения комплексной оценки  $C^*$  достоверности полученного решения.

Предложенный алгоритм позволяет на основании сопоставления имеющихся входных данных с антецедентами нечетких правил выбрать решающее правило, выходное значение которого определяет искомое состояние объекта. Таким образом, для решения практических задач по оценке состояния объектов в условиях неопределенности необходимо сформировать систему правил вида (4). Для этого разработана соответствующая нейронечеткая модель на основе обучения нечеткой нейронной сети [Katasev et al., 2016].

### 3. Построение нейронечеткой модели формирования нечетких правил

Для построения нейронечеткой модели, формирующей систему нечетких правил для оценки состояния объекта, требуется определить ее структуру и обучить на имеющихся данных, характеризующих моделируемый объект. Структура разработанной нечеткой нейронной сети определяется следующими компонентами [Katasev et al., 2016]:

1) составом нейронов входного слоя нечеткой нейронной сети (определяется составом входных переменных объекта, на которых происходит обучение сети);

2) составом нейронов слоя значений-градаций сети (определяется количеством значений (градаций)  $\vec{A}_i$  каждой входной переменной);

3) составом нейронов слоя значений выходного нейрона (определяется числом значений выходной переменной  $y$  — числом состояний моделируемого объекта);

4) числом слоев сети и их функциональностью (определяется алгоритмом логического вывода на системе правил вида (4)).

На рис. 1 приведен пример структуры нечеткой нейронной сети.

Представленная на рисунке нечеткая нейронная сеть состоит из двух входных нейронов, имеющих соответственно по два и три значения (градации), одного выходного нейрона с тремя значениями и включает 6 функциональных слоев. Каждый маршрут в нечеткой нейронной сети от  $(x_1, x_2)$  к  $y$  задает соответствующее нечетко-продукционное правило вида (4). Общее число маршрутов соответствует произведению числа  $I$ -нейронов и числа нейронов в пятом слое сети. В данном случае сеть задает 18 нечетких правил.

Рассмотрим состав, назначение слоев сети и используемые в ней обозначения:

- 1-й слой (входной): содержит множество входных нейронов, выполняющих распределение входных сигналов по нечеткой нейронной сети;
- 2-й слой (слой значений-градаций входных нейронов): содержит множество  $\vec{A}$ -нейронов, каждый из которых вычисляет значение соответствующей функции принадлежности  $\mu_{\vec{A}}(x^*)$ ;
- 3-й слой: содержит множество  $I$ -нейронов, каждый из которых вычисляет оценку  $R$  по формуле (5) как минимальное из значений соответствующих функции принадлежности;
- 4-й слой: содержит множество  $RT$ -нейронов, каждый из которых вычисляет произведение соответствующих оценок  $R$  и  $T$ , где  $T$  вычисляется по формуле (6);

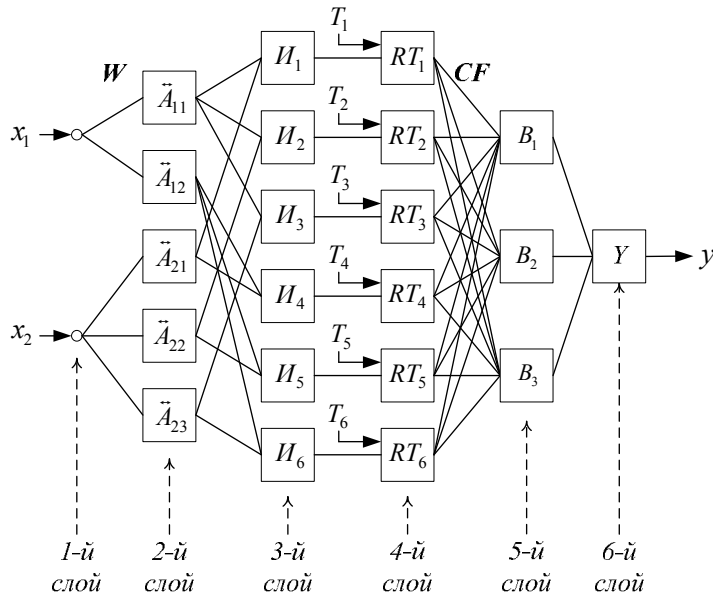


Рис. 1. Пример структуры разработанной нечеткой нейронной сети (здесь  $x_1$  и  $x_2$  — входы сети,  $y$  — выход сети,  $W$  и  $CF$  — матрицы весов связей нейронов; используемые обозначения нейронов приведены в тексте)

- 5-й слой (слой значений выходного нейрона сети): содержит множество  $B$ -нейронов, каждый из которых вычисляет соответствующие комплексные оценки достоверности  $C$  по формуле (7) и формирует на выходе максимальное значение из вычисленных оценок;
- 6-й слой (выходной): содержит выходной  $Y$ -нейрон, формирующий значение выхода сети  $y = B$ , соответствующее  $B$ -нейрону с максимальной оценкой  $C$ .

В качестве  $W$  обозначена матрица весов связей нейронов 1-го и 2-го слоев сети, а  $CF$  — матрица весов связей нейронов 4-го и 5-го слоев.

Обучение нечеткой нейронной сети потребовало разработки соответствующих методов и алгоритмов инициализации и настройки значений ее параметров (параметров функций принадлежности и элементов матриц весовых коэффициентов  $CF$  и  $W$ ).

Для определения начальных значений параметров функций принадлежности разработан вычислительный метод, основанный на кластеризации значений каждой из количественных входных переменных и покрытия полученных кластеров функциями принадлежности конкретного вида. На рис. 2 представлены пример кластеризации значений входной переменной и их соответствие состояниям моделируемого объекта.

В данном случае сформировано три кластера значений входной переменной. В качестве алгоритма кластеризации используется алгоритм  $k$ -средних. При задании различного числа  $k$  формируется соответствующее количество кластеров.

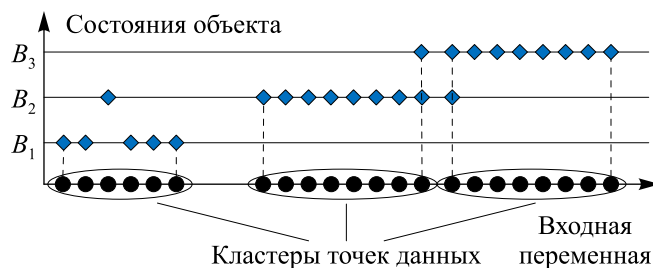


Рис. 2. Пример кластеризации значений входной переменной и их соответствие состояниям объекта (здесь  $B_1$ ,  $B_2$  и  $B_3$  — возможные состояния объекта)

В настоящее время в системах нечеткого моделирования наибольшее распространение получили треугольные и трапециевидальные формы функций принадлежности. На рис. 3 показан пример покрытия кластеров точек данных треугольными функциями принадлежности.

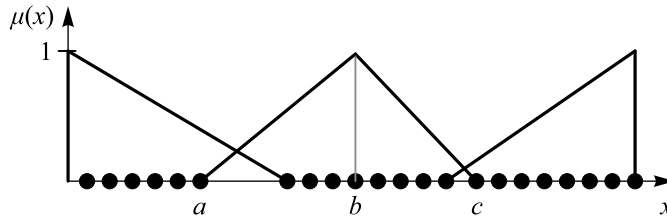


Рис. 3. Пример покрытия кластеров треугольными функциями принадлежности (здесь  $x$  — входная переменная,  $\mu(x)$  — функция принадлежности;  $a, b, c$  — ее параметры)

Таким образом, каждая функция принадлежности покрывает соответствующий кластер точек данных и, в случае треугольной формы, имеет начальные значения параметров  $a$  (левое основание),  $b$  (мода) и  $c$  (правое основание). Для трапециевидальной формы функции принадлежности инициализация значений ее параметров производится аналогично.

Для определения начальных значений элементов матриц весов  $CF$  и  $W$  разработаны соответствующие вычислительные методы, основанные на статистическом подходе. Так как элементы матрицы  $CF$  в нечеткой нейронной сети являются достоверностью правил следующего вида: ЕСЛИ  $x_1 = \vec{A}_1(w_1)$  И ...  $x_i = \vec{A}_i(w_i)$  И ...  $x_n = \vec{A}_n(w_n)$  ТО  $y = B[CF]$ , то веса  $CF$  определяются на основе данных обучающей выборки по формуле

$$CF = \frac{N_R}{N_B}, \tag{8}$$

где  $N_R$  — число примеров, соответствующих шаблону правила и имеющих значение выхода  $B$ ,  $N_B$  — общее число примеров со значением выхода  $B$ .

Аналогично: формула расчета значения веса  $w_i$ , соответствующего условию в правиле  $x_i = \vec{A}_i$ , определяется на основе данных обучающей выборки:

$$w_i = \frac{n}{N}, \tag{9}$$

где  $n$  — число примеров, соответствующих условию  $x_i = \vec{A}_i$ ,  $N$  — объем выборки.

Для настройки значений параметров нечеткой нейронной сети разработан вычислительный метод простой генетической оптимизации, схема которого представлена на рис. 4.

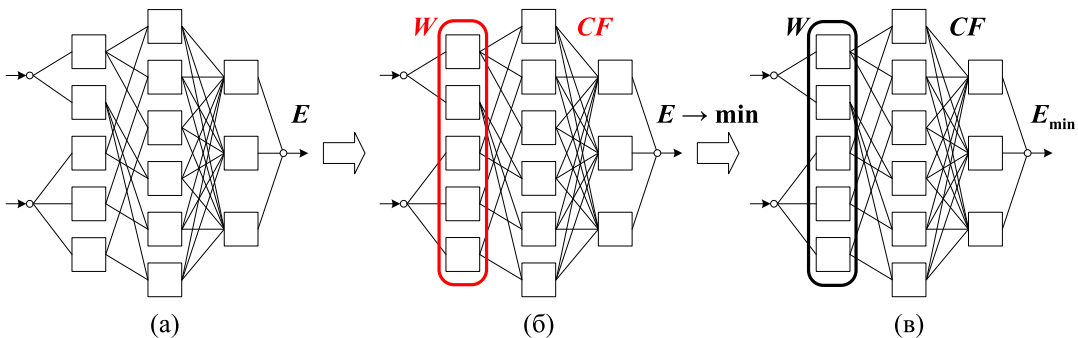


Рис. 4. Схема метода настройки значений параметров нечеткой нейронной сети: а) исходная нейронная сеть; б) этап обучения сети; в) обученная сеть;  $W$  и  $CF$  — матрицы весов связей нейронов;  $E$  — бутстрэп-ошибка сети



Исходная нечеткая нейронная сеть имеет начальные значения параметров, вычисленные на основе методов инициализации. Обучение сети происходит с использованием разработанного генетического алгоритма. Искомая нечеткая нейронная сеть представляет модель с оптимизированными значениями параметров. Таким образом, задача обучения нечеткой нейронной сети заключается в настройке значений параметров функций принадлежности для градаций входных нейронов, а также в определении элементов матриц весов  $W$  и  $CF$  для минимизации бутстрэп-ошибки нечеткой нейронной сети на данных из обучающей и тестовой выборок.

Значение бутстрэп-ошибки  $E$  вычисляется по формуле [Smaga, 2017]

$$E = \alpha * \epsilon_{test} + \beta * \epsilon_{train}, \tag{10}$$

где  $\alpha = 0.632$  и  $\beta = 0.368$  — коэффициенты бутстрэпирования,  $\epsilon_{train} = \frac{n_{train}}{N_{train}}$  — ошибка обучения

( $n_{train}$  — число ошибок при обучении,  $N_{train}$  — объем обучающей выборки),  $\epsilon_{test} = \frac{n_{test}}{N_{test}}$  — ошибка тестирования ( $n_{test}$  — число ошибок при тестировании,  $N_{test}$  — объем тестовой выборки).

Для реализации генетического алгоритма потребовалось кодирование параметров задачи. Пусть имеются следующие множества:

- $\{\hat{x}_1, \dots, \hat{x}_g, \dots, \hat{x}_G\}$  — множество входных нейронов  $\hat{x}_g$  ( $g = 1..G$ ) с градациями,  $G \leq n$ , где  $n$  — общее число входных нейронов;
- $\{c_1, \dots, c_g, \dots, c_G\}$  — множество числа градаций  $c_g$  входных нейронов;
- $\{\tilde{A}_{11}, \dots, \tilde{A}_{1j_1}, \dots, \tilde{A}_{1c_1}, \dots, \tilde{A}_{g1}, \dots, \tilde{A}_{gj_g}, \dots, \tilde{A}_{gc_g}, \dots, \tilde{A}_{G1}, \dots, \tilde{A}_{Gj_G}, \dots, \tilde{A}_{Gc_G}\}$  — множество всех градаций, каждая из которых задана соответствующей функцией принадлежности.

Рассмотрим пример кодирования параметров ( $a, b, c$ ) у треугольной функции принадлежности в виде соответствующих хромосом. Введем понятие  $\Delta$ -окрестности для значений ее параметров:  $\Delta_a = [a_{min}, a_{max}]$ ,  $\Delta_b = [b_{min}, b_{max}]$ ,  $\Delta_c = [c_{min}, c_{max}]$ , где величина  $\Delta$  определяется индивидуально для каждого параметра. Разобьем все  $\Delta$ -окрестности на  $2^m - 1$  интервалов, где  $m$  — целое число. Тогда все параметры функции принадлежности смогут принимать одно из  $2^m$  значений, а хромосома для значений параметров всех функций принадлежности будет иметь вид

$H = \sum_{g=1}^G \sum_{j_g=1}^{c_g} (H_{j_g}^a + H_{j_g}^b + H_{j_g}^c)$ , где «+» — операция конкатенации хромосом  $H_{j_g}^a$ ,  $H_{j_g}^b$  и  $H_{j_g}^c$

для значений параметров функций принадлежности. Так, для параметра  $a$  хромосома

$H_{j_g}^a = (h_{1j_g}^a, h_{2j_g}^a, \dots, h_{mj_g}^a) \in \{(\overbrace{0, 0, \dots, 0}^m), (\overbrace{0, 0, \dots, 1}^m), \dots, (\overbrace{1, 1, \dots, 1}^m)\}$ , где  $(\overbrace{0, 0, \dots, 0}^m)$  соответствует

минимальному значению параметра, а  $(\overbrace{1, 1, \dots, 1}^m)$  — максимальному значению. На рис. 5 приведен пример кодирования значений параметров функции принадлежности для градации  $\tilde{A}_{j_g}$ .

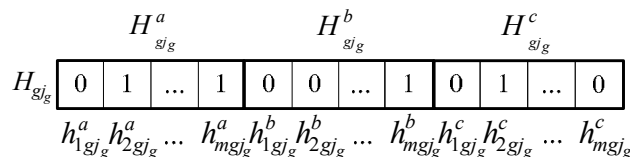


Рис. 5. Пример кодирования значений параметров функции принадлежности (здесь  $H_{j_g}^a$ ,  $H_{j_g}^b$ ,  $H_{j_g}^c$  — хромосомы для кодирования соответствующих значений параметров  $a, b$  и  $c$ ;  $h$  — гены соответствующих хромосом;  $H_{j_g}$  — хромосома для кодирования функции принадлежности)

Для всего слоя градаций в нечеткой нейронной сети любая хромосома  $H$  будет состоять из хромосом  $H_{g_j}$ , общее число которых равно  $\sum_{g=1}^G c_g$ :  $H = \sum_{g=1}^G \sum_{j_g=1}^{c_g} H_{g_j}$ .

В качестве фитнес-функции используется бутстрэп-ошибка нечеткой нейронной сети:

$$F(H) = \alpha * \frac{n_{test}}{N_{test}} + \beta * \frac{n_{train}}{N_{train}}, \quad (11)$$

где  $\alpha = 0.632$  и  $\beta = 0.368$  — коэффициенты бутстрэпирования,  $n_{train}$  — число ошибок классификации при обучении,  $N_{train}$  — объем обучающей выборки,  $n_{test}$  — число ошибок классификации при тестировании,  $N_{test}$  — объем тестовой выборки.

Критерием выбора лучшей хромосомы является минимизация бутстрэп-ошибки нечеткой нейронной сети, соответствующей выражению (11):  $F(H) \rightarrow \min_{\forall H}$ .

С учетом введенных обозначений и способов кодирования параметров задачи представим разработанный генетический алгоритм для обучения нечеткой нейронной сети. Предложенный алгоритм состоит из следующих этапов.

1. *Создание начальной популяции хромосом  $H_q$  объемом  $v$  ( $q = 1..v$ ) для значений параметров всех функций принадлежности: родительская хромосома из набора хромосом, соответствующих начальным значениям параметров функций принадлежности, и набор потомков, полученных в результате случайной (с вероятностью 0.5) мутации ее генов.*

2. Для каждой хромосомы из начальной популяции определение значений элементов матриц весов  $CF$  и  $W$  по формулам (8) и (9) соответственно.

3. *Оценка приспособленности каждой хромосомы  $H_q$  начальной популяции на основе фитнес-функции с вычислением значений  $F(H_q)$ .*

4. *Селекция двух родительских хромосом для скрещивания по методу колеса рулетки с вероятностью выбора  $p(H_q) = (1 - F(H_q)) / \sum_{q=1}^v (1 - F(H_q))$ .*

5. *Скрещивание хромосом: выполнение операции кроссинговера над родительскими хромосомами для получения двух дочерних хромосом.*

6. *Мутация: инверсия с вероятностью 0.02 генов дочерних хромосом.*

7. Для каждой дочерней хромосомы определение значений элементов матриц весов  $CF$  и  $W$  по формулам (8) и (9).

8. *Оценка приспособленности дочерних хромосом на основе фитнес-функции.*

9. *Редукция: удаление двух худших хромосом из текущей популяции с максимальными значениями фитнес-функции.*

10. Повторять шаги 4–9 до момента, когда в течение определенного числа поколений значение фитнес-функции не будет улучшаться.

11. Из текущего набора выбрать лучшую хромосому  $H_{q^*}$ :  $F(H_{q^*}) = \min_{\forall H_q} F(H_q)$  и считать нечеткую нейронную сеть, соответствующую выбранной хромосоме, обученной.

Таким образом, в результате обучения нечеткой нейронной сети определяются значения параметров функций принадлежности, элементов матриц весов  $W$  и  $CF$  — производится формирование системы нечетких правил с идентифицированными значениями параметров.

#### 4. Оценка классифицирующей способности нечетких моделей

На основе предложенных методов и алгоритмов разработан программный комплекс для формирования нечетких правил оценки состояния объектов. В качестве языка реализации выбран объектно ориентированный язык программирования *Java*. Разработка программного комплекса осуществлялась в среде *NetBeans IDE*. С использованием программного комплекса про-

ведены исследования по оценке классифицирующей способности формируемых нечетких моделей на примере анализа данных из источника *UCI Machine Learning Repository* [Bache, Lichman, 2013]. В таблице 2 представлены характеристики исходных данных.

Таблица 2. Характеристики исходных данных для анализа

Набор данных	Число входных переменных	Типы входных переменных	Объем выборки	Число классов
Iris Plants Database	4	числовые	150	3
BUPA Liver Disorders	6	числовые	345	2
Australian Credit Approval	14	числовые, категориальные	690	2
German Credit Data	20	числовые, категориальные	1000	2

Первый набор данных соответствует задаче классификации видов ирисов Фишера. Во втором наборе представлены данные по задаче оценки состояния печени человека по результатам анализа крови. Третий набор описывает задачу выявления подозрительных транзакций с банковскими картами. Четвертый набор характеризует задачу принятия решения о выдаче потребительского кредита на основании анкетных данных заемщика.

Для оценки классифицирующей способности формируемых нечетких моделей при анализе наборов данных проведен ряд исследований, основанных на выполнении следующих этапов:

1) построение систем нечетко-продукционных правил для аппроксимации зависимостей в каждом наборе данных;

2) сравнение результатов классификации на основе сформированных систем правил с известными результатами классификации других авторов.

На первом этапе с помощью разработанного программного комплекса были сформированы четыре базы знаний, соответствующие анализируемым наборам данных. В качестве меры эффективности сформированных баз знаний выступала точность классификации. Данная величина рассчитывается как отношение числа правильно классифицированных входных образов к общему числу данных в обучающих выборках.

Для определения значимости полученных результатов классификации произведено их сравнение с известными результатами других авторов, проводивших исследования на тех же наборах данных. Так, в работах [Бухтояров, 2012; Воронцов, Каневский, 2005; Сергиенко, 2010; Scharif, 2001; Sergienko, Seminkin, 2011] проводились исследования эффективности различных методов классификации на наборах данных BUPA Liver Disorders, Australian Credit Approval и German Credit Data. В таблице 3 приведено сравнение точности классификации на основе сформированных нечетких моделей с точностью других методов классификации.

Из таблицы видно, что точность классификации на основе сформированных нечетких моделей превосходит точность других методов классификации от 1 до 15 %. Значимость полученных результатов на данном этапе исследований определяется возможностью практического использования нечетких моделей для решения задач определения состояния объектов с точностью, не уступающей точности других известных методов классификации.

В работе [Штовба, 2003] приведены результаты исследования эффективности метода нечеткой классификации на наборе данных Iris Plants Database. Данный метод был специально разработан автором для выполнения нечеткого логического вывода в среде MATLAB (в пакете расширения Fuzzy Logic Toolbox) при аппроксимации объектов с дискретным выходом. Для полноты экспериментов на том же наборе данных построен нейросетевой классификатор (многослойный перцептрон) на базе аналитической платформы Deductor, а также спроектирован нейронечеткий классификатор ANFIS [Jang, Sun, 1993] инструментальными средствами среды моделирования MATLAB.

В таблице 4 приведено сравнение точности классификации, полученной при использовании сформированной нечеткой модели на наборе данных Iris Plants Database, с точностью ней-

росетевого, нейронечеткого методов классификации, а также метода нечеткой классификации объектов с дискретным выходом.

Как видно из таблицы, точность классификации на основе формирования нечеткой модели сравнима или превосходит точность других методов классификации. Преимущество использования предложенного метода классификации перед нечетким и нейронечетким методами заключается в повышении точности классификации, а следовательно, в возможности принятия более точных решений по оценке состояния объектов.

Качество обучения нечеткой нейронной сети в первую очередь определяется полнотой данных в обучающей выборке, их репрезентативностью. Как правило, выборки данных имеют пропущенные значения. Рассмотренные методы классификации не рассчитаны на обработку таких данных и требуют предварительного заполнения пропущенных значений, например, экспертными оценками (нечеткими данными), средними значениями по выборке и т. д. Однако существующие методы заполнения пропущенных значений в данных являются часто субъективными, требующими, например, использования априорной информации о виде распределения значений входных параметров. Это является сдерживающим фактором для их эффективного использования. Поэтому актуально применение методов, не требующих борьбы с пропущенными значениями и способных эффективно работать с неполными выборками данных. Этому требованию удовлетворяют формируемые нечеткие модели.

В таблице 5 представлены результаты оценки точности нечетких моделей при классификации исходных наборов данных, а также наборов данных с отсутствующими значениями, полученными удалением случайным образом части значений входных переменных.

Таблица 3. Сравнение точности различных методов классификации

Метод классификации	Наборы данных	BUPA Liver Disorders	Australian Credit Approval	German Credit Data
Коллективный классификатор на нечеткой логике		0.757	0.921	0.821
Классификатор на нечеткой логике		0.725	0.891	0.794
Байесовский классификатор		0.629	0.847	0.679
Многослойный персептрон		0.693	0.833	0.716
Бустинг		0.656	0.76	0.7
Бэггинг		0.63	0.847	0.684
Метод случайных подпространств		0.632	0.852	0.677
Коллектив нейронных сетей: простое усреднение		0.74	0.892	0.805
Коллектив нейронных сетей: равноправное голосование		0.783	0.918	0.815
Коллектив нейронных сетей: правило Борда		0.772	0.905	0.831
Коллектив нейронных сетей: многоярусное обобщение		0.785	0.925	0.852
Коллектив нейронных сетей: трехступенчатый эволюционный метод		0.804	0.947	0.857
Козволюционный метод обучения алгоритмических композиций		0.644	0.866	0.746
<i>Сформированные нечеткие модели</i>		<i>0.846</i>	<i>0.952</i>	<i>0.862</i>

Таблица 4. Сравнение точности различных методов классификации на наборе данных Iris Plants Database

Методы классификации			
Метод нечеткой классификации объектов с дискретным выходом	Нейросетевой метод на основе многослойного персептрона	Нейронечеткий метод на основе нечеткой нейронной сети ANFIS	<i>Метод классификации на основе нечеткой модели</i>
0.947	0.987	0.973	<i>0.987</i>

Таблица 5. Точность классификации наборов данных на основе сформированных нечетких моделей

Набор данных	% отсутствующих данных				
	0	5	10	15	20
Iris Plants Database	0.987	0.967	0.92	0.867	0.78
BUPA Liver Disorders	0.846	0.751	0.719	0.667	0.574
Australian Credit Approval	0.952	0.855	0.836	0.826	0.793
German Credit Data	0.862	0.825	0.811	0.798	0.76

Результаты проведенных исследований показали, что предложенный подход к классификации на основе формирования нечетких моделей эффективно работает как на полных выборках данных, так и на выборках данных с пропущенными значениями. При этом с увеличением объема пропущенных значений точность классификации снижается незначительно. Это указывает на значимость полученных результатов и эффективность предложенного подхода для оценки состояния объектов в условиях отсутствия части исходных данных.

## 5. Решение практической задачи по оценке состояния объектов

С целью апробации произведено формирование нечетких правил для решения практической задачи по оценке состояния водоводов на кустовых насосных станциях в нефтяной отрасли [Katasev, Kataseva, 2016]. Автоматизация оценки состояния водоводов потребовалась для повышения эффективности выявления утечек из водоводов (порывов) по результатам анализа получасовых расходов жидкости. На примере данной задачи реализована система оперативного выявления порывов на водоводах, принимающая решение на основании сформированной базы нечетко-продукционных правил. Дистанционно факт утечки косвенно устанавливается путем анализа расходов жидкости на водоводах и на выкиде кустовой насосной станции.

На рис. 6 представлена типовая схема размещения водоводов.

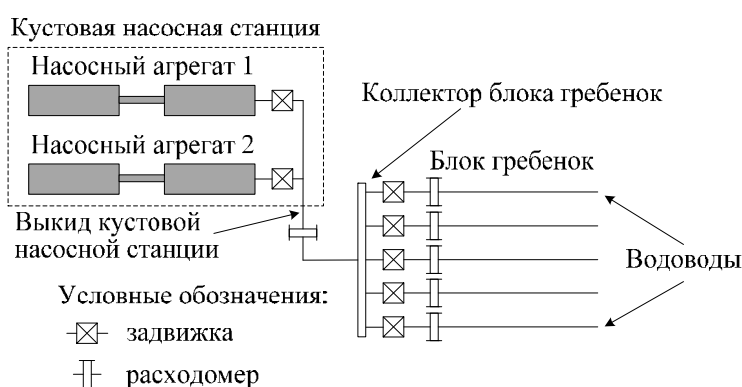


Рис. 6. Типовая схема размещения водоводов на кустовой насосной станции

В данном случае в системе имеется пять водоводов, размещающихся на блоке гребенок. На каждом водоводе имеется прибор учета расхода жидкости (расходомер), показания которого фиксируются каждые 0.5 часа и сохраняются в базе данных.

Разработанная система решает задачу оценки состояния водоводов с целью выявления нежелательных тенденций закачки жидкости и оповещает диспетчера о наступлении аварийных ситуаций на основе сформированной базы нечетких правил. Для их формирования использовалась разработанная нейронечеткая модель, с помощью которой обрабатывалась статистическая

информация по водоводам, собранная за 2 года. В качестве исходных данных для анализа использовались значения следующих переменных:

- а) получасовые расходы жидкости на водоводах ( $\text{м}^3$ ):
  - $Q_0$  — текущий расход по водоводу,
  - $Q_1$  — расход по водоводу за предыдущие полчаса,
  - $Q_2$  — расход по водоводу за предыдущий час;
- б) показатели давления (МПа):
  - $P_0$  — текущее давление в коллекторе,
  - $P_1$  — предыдущее давление в коллекторе.

Для подготовки обучающих выборок рассчитаны относительные отклонения расхода жидкости по каждому водоводу за полчаса и за час по формуле

$$\varepsilon = \frac{Q_0 - Q}{Q} \cdot 100 \%,$$

где  $Q \in \{Q_1, Q_2\}$ .

Кроме того, рассчитаны изменения давлений в коллекторе:  $\Delta P = P_1 - P_0$ .

Таким образом, обучающие выборки включали значения следующих входных параметров:

- $\varepsilon_1$  — отклонение расхода жидкости по водоводу за 0.5 часа,
- $\varepsilon_2$  — отклонение расхода жидкости по водоводу за 1 час,
- $\Delta P$  — уменьшение давления в коллекторе.

В качестве выходной выступала переменная  $D$  (состояние водовода), принимающая одно из двух возможных значений: «норма» или «порыв». Значения указанных переменных составляли группы «входы – выход» по каждому водоводу на кустовой насосной станции. Общее число станций составляло 28, а число водоводов — 303. В результате обучения нечетких нейронных сетей на полученных данных сформировано 28 систем нечетко-продукционных правил. В среднем число правил в каждой системе составило 12. Общее число правил определения состояния водоводов составило 342.

Разработанная нейронечеткая модель успешно прошла тестирование и апробацию в составе интеллектуальной системы поддержки принятия решений по оценке состояния водоводов. Для проверки эффективности работы системы проведен анализ статистической информации о расходах жидкости на водоводах цеха поддержания пластового давления нефтегазодобывающего управления «ДжалильНефть» ОАО «ТатНефть». Анализируемая информация представляла собой получасовые значения расходов жидкости по всем водоводам цеха за 1 год. Исходные данные представляли текстовый файл размером более 300 МБ, содержащий более двух миллионов записей о расходах жидкости по каждому из водоводов.

В ходе проведения анализа решалась задача определения эффективности работы алгоритма логического вывода на правилах базы знаний интеллектуальной системы оперативного выявления порывов на водоводах. Ожидаемым результатом было определение множества аварийных ситуаций, связанных с утечками жидкости, возникшими за исследуемый промежуток времени. Критерием эффективности работы программы послужил факт фиксирования всех фактических аварий на водоводах, выявленных ранее по результатам экспертного анализа.

Таким образом, в целях апробации сформирована база знаний и разработана экспертная система для оценки состояния водоводов на предмет наличия порывов. Разработанная система внедрена в промышленную эксплуатацию на диспетчерском пункте в ОАО «ТатНефть». При работе система показала высокую эффективность алгоритма обнаружения порывов, что подтверждено 100%-м уровнем выявления аварийных ситуаций на водоводах. Средняя точность оценки состояния водоводов составила 93 %. Использование системы позволило сократить среднее время реакции на утечки из водоводов на 12 часов (повышение эффективности на 50 %) и повысить точность оценки состояния водоводов на 20 % по сравнению с экспертным (ручным) подходом.

## 6. Заключение

Описанная в работе нейронечеткая модель позволяет автоматизировать процессы формирования нечетких правил для оценки состояния объектов в условиях неопределенности. Исследование нечетких правил, сформированных на основе обучения нечеткой нейронной сети на известных наборах данных, показало их высокую классифицирующую способность, в том числе при тестировании на данных с пропущенными значениями.

Предложенный подход к формированию нечетких правил успешно прошел апробацию на кустовых насосных станциях в системах поддержания пластового давления при решении практической задачи оценки состояния водоводов на предмет возможных утечек. Результаты апробации показали высокую эффективность разработанного математического обеспечения и пригодность нейронечеткой модели к формированию нечетких правил для оценки состояния объектов в нефтяной отрасли. При этом в силу общности предложенного подхода к формированию нечетких правил можно утверждать, что разработанная нечеткая нейронная сеть может быть эффективно использована в качестве инструмента для автоматизированного формирования и практического использования нечетких правил и в других предметных областях, в которых актуально решать задачу по оценке состояния объектов в условиях неопределенности.

В перспективе, с целью развития методологии автоматизированного формирования нечетких правил принятия решений, целесообразны совершенствование разработанного математического обеспечения, расширение классов решаемых задач, а также разработка, внедрение и практическое использование интеллектуальных систем оценки состояния объектов и поддержки принятия решений в различных предметных областях.

## Список литературы (References)

- Бухтояров В. В.* Трехступенчатый эволюционный метод формирования коллективов нейронных сетей для решения задач классификации // Программные продукты и системы. — 2012. — № 4. — С. 101–106.  
*Buhtoyarov V. V.* Trekhstupenchatyj ehvolyucionnyj metod formirovaniya kollektivov nejronnyh setej dlya resheniya zadach klassifikacii [Three-step evolutionary method of forming teams of neural networks for solving classification problems] // Software products and systems. — 2012. — No. 4. — P. 101–106 (in Russian).
- Воронцов К. В., Каневский Д. Ю.* Коэволюционный метод обучения алгоритмических композиций // Таврический вестник информатики и математики. — 2005. — № 2. — С. 51–66.  
*Voroncov K. V., Kanevskij D. Yu.* Koehvolyucionnyj metod obucheniya algoritmicheskikh kompozicij [Coevolutionary method of teaching algorithmic compositions] // Tavrichesky herald of computer science and mathematics. — 2005. — No. 2. — P. 51–66 (in Russian).
- Сергиенко Р. Б.* Метод формирования нечеткого классификатора самонастраивающимися коэволюционными алгоритмами // Искусственный интеллект и принятие решений. — 2010. — № 3. — С. 98–106.  
*Sergienko R. B.* Metod formirovaniya nechetkogo klassifikatora samonastraivayushchimisya koevolyucionnymi algoritmami [The method of forming a fuzzy classifier by self-tuning coevolutionary algorithms] // Artificial Intelligence and Decision Making. — 2010. — No. 3. — P. 98–106 (in Russian).
- Штовба С. Д.* Идентификация нелинейных зависимостей с помощью нечеткого логического вывода в системе MATLAB // Математика в приложениях. — 2003. — № 2 (2). — С. 9–15.  
*Shtovba S. D.* Identifikaciya nelinejnyh zavisimostej s pomoshchyu nechetkogo logicheskogo vyvoda v sisteme MATLAB [Identification of nonlinear relationships using fuzzy inference system in MATLAB] // Mathematics in Applications. — 2003. — No. 2 (2). — P. 9–15 (in Russian).
- Akhmetvaleev A. M., Katasev A. S.* Neural network model of human intoxication functional state determining in some problems of transport safety solution // Computer Research and Modeling. — 2018. — No. 10 (3). — P. 285–293.
- Bache K., Lichman M.* UCI Machine Learning Repository [<http://archive.ics.uci.edu/ml>]. — Irvine, CA: University of California, School of Information and Computer Science, 2013.

- Ge C., Wang B., Wei X., Liu Y.* Exponential synchronization of a class of neural networks with sampled-data control // *Applied Mathematics and Computation*. — 2017. — No. 315. — P. 150–161.
- Guskov G., Namestnikov A., Yarushkina N.* Approach to the search for similar software projects based on the UML ontology // *Advances in Intelligent Systems and Computing*. — 2018. — No. 680. — P. 3–10.
- Ismagilov I. I., Khasanova S. F., Katasev A. S., Kataseva D. V.* Neural network method of dynamic biometrics for detecting the substitution of computer // *Journal of Advanced Research in Dynamical and Control Systems*. — 2018. — No. 10 (10 Special Issue). — P. 1723–1728.
- Jang J. R., Sun C. T.* ANFIS: Adaptive-Network-based Fuzzy Inference Systems // *IEEE Trans. on Systems, Man and Cybernetics*. — 1993. — Vol. 23. — P. 665–685.
- Katasev A. S., Kataseva D. V.* Expert diagnostic system of water pipes gusts in reservoir pressure maintenance processes // 2nd International Conference on Industrial Engineering, Applications and Manufacturing, ICIEAM 2016 — Proceedings, 7911651.
- Katasev A. S., Kataseva D. V., Emaletdinova L. Yu.* Neuro-fuzzy model of complex objects approximation with discrete output // 2nd International Conference on Industrial Engineering, Applications and Manufacturing, ICIEAM 2016 — Proceedings, 7911653.
- Liu X., Wang H., Gao C., Chen M.* Adaptive fuzzy funnel control for a class of strict feedback nonlinear systems // *Neurocomputing*. — 2017. — No. 241. — P. 71–80.
- Namestnikov A. M., Filippov A. A., Avvakumova V. S.* An ontology-based model of technical documentation fuzzy structuring // *CEUR Workshop Proceedings*. — 2016. — No. 1687. — P. 63–74.
- Rauch J.* Expert deduction rules in data mining with association rules: a case study // *Knowledge and Information Systems*. — 2019. — No. 59 (1). — P. 167–195.
- Tron E., Margaliot M.* Mathematical Modeling of Observed Natural Behavior: a Fuzzy Logic Approach // *Fuzzy Sets and Systems*. — 2004. — Vol. 146. — P. 437–450.
- Hassan N., Sayed O. R., Khalil A. M., Ghany M. A.* Fuzzy Soft Expert System in Prediction of Coronary Artery Disease // *International Journal of Fuzzy Systems*. — 2017. — No. 19 (5). — P. 1546–1559.
- Schapire R.* The boosting approach to machine learning: An overview // *MSRI Workshop on Nonlinear Estimation and Classification*, Berkeley, CA, 2001. — 23 p.
- Sergienko R. B., Semenkin E. S.* Michigan and Pittsburgh Methods Combining for Fuzzy Classifier Generating with Coevolutionary Algorithm for Strategy Adaptation. — *Proc. of 2011 IEEE Congress on Evolutionary Computation*, New Orleans, LA, USA, 2011.
- Smaga L.* Bootstrap methods for multivariate hypothesis testing // *Communications in Statistics: Simulation and Computation*. — 2017. — No. 46 (10). — P. 7654–7667.
- Vaskovic M., Kodogiannis V. S., Budimir D.* An adaptive fuzzy logic system for the compensation of nonlinear distortion in wireless power amplifiers // *Neural Computing and Applications*. — 2018. — No. 30 (8). — P. 2539–2554.
- Wachla D., Moczulski W. A.* Identification of dynamic diagnostic models with the use of methodology of knowledge discovery in databases // *Engineering Applications of Artificial Intelligence*. — 2007. — No. 20 (5). — P. 699–707.
- Yarushkina N.* Soft computing and complex system analysis // *International Journal of General Systems*. — 2001. — No. 30 (1). — P. 71–88.
- Zadeh L. A.* Fuzzy Sets // *Information and Control*. — 1965. — Vol. 8. — P. 338–353.