

УДК 519.86

Разработка методов и алгоритмов интеллектуальной поддержки принятия решений в системах управления кадрами

А.Н. Даниленко

Аннотация

В данной работе предлагаются методы и алгоритмы интеллектуальной поддержки принятия управленческих решений на основе нейронечетких сетей. Разработан алгоритм автоматической генерации базы знаний в соответствии с разработанными критериями полноты и минимальности. Произведено редуцирование пространства признаков на основе экспертных оценок специалистов.

Ключевые слова

система управления; принятие решений; интеллектуальная поддержка; нечеткая логика; нейронные сети.

Управление современными предприятиями требует все большей оперативности от руководителей. В период быстрых изменений на рынке, более короткого цикла обращения продукции и услуг, изменчивости потребительского спроса важны полнота и актуальность информационной базы для принятия стратегических решений, а также контроля за их выполнением. В этой связи руководители сталкиваются с необходимостью принимать множество решений, опираясь при этом на результаты обработки больших объемов данных, которая должна осуществляться в сжатые сроки. При этом возникает потребность в разработке систем интеллектуальной поддержки процесса принятия управленческих решений на базе современных информационных технологий. Однако разработка таких систем принадлежит к областям, наиболее трудно поддающимся автоматизации.

Технологии принятия кадровых решений сегодня в той или иной степени опираются на психодиагностические данные: индивидуальные показатели, полученные при диагностике личности работников или кандидатов на вакантные должности, которые позволяют определить степень соответствия испытуемого заданным требованиям профессии или должности. Возможности психодиагностического анализа расширяются еще больше, если в

диагностический комплекс включаются критериально ориентированные тесты, регистрирующие уровень специальных знаний и навыков, - таким образом диагностическим измерениям подвергаются не только личностные, но и профессиональные качества испытуемого.

Задача прогнозирования особенностей поведения человека на основе психодиагностики включает подзадачи как диагностики и интерпретации данных, так и предсказания некоторых событий на основании определенной модели.

В настоящее время создано большое количество разнообразных диагностических инструментов (AVELife TestGold Studio, «Профессор 2000», «Профессор – Кадры» и другие), способных зарегистрировать фактически любое описанное заказчиком свойство человека. Однако, даже получив результаты диагностики относительно интересующих его свойств, как диагност, так и заказчик зачастую плохо представляют себе, какого поведения следует ожидать от обследуемого, в чем проявятся или не проявятся эти свойства. Постановка большинства практических задач предполагает «на выходе» не просто описательную характеристику особенностей обследуемых «здесь и теперь», но и прогноз поведения этих людей в различных ситуациях, желательно на длительный срок. Иными словами, на выходе получается объемный симптомокомплекс с неконтролируемой интерпретацией.

В связи с этим появляется необходимость в разработке систем интеллектуальной поддержки принятия управленческих решений, которые позволяют не только присваивать данным или выводам определенную вероятность, но и преобразовывать эту вероятность по мере обработки данных и поступления новых.

Ни один из существующих на рынке программных продуктов не отвечает этим необходимым требованиям.

Предлагаемые в данной работе методы и алгоритмы в некоторой степени преодолевают указанные выше недостатки. Рассмотрим их на примере задачи принятия решений в вопросах управления персоналом.

Задачу принятия решения о целесообразности приема на работу можно отнести в общем виде к задаче классификации, то есть отнесению соискателя к одному из классов: кандидат полностью соответствует требованиям специальности, в основном отвечает требованиям специальности, частично соответствует, не соответствует.

Из-за большого количества параметров, влияющих друг на друга, возникает многофакторная неопределенность, в связи с чем становится невозможным определить вид целевой функции для определения степени влияния каждого фактора на результат классификации. Применение факторного анализа данных при этом не дает желаемых

результатов и не приводит к сокращению размерности пространства признаков классификации [1]. Поэтому возникает необходимость применения метода экспертных оценок. Это помогает произвести редуцирование пространства признаков, но не решает проблему неопределенности. Для решения этой проблемы в данной работе предлагается использовать аппарат нейронных сетей.

Так как информация, на основе которой принимается решение о профпригодности кандидата, является результатами различных психологических тестов, классифицируемые данные являются неточными или недостаточно определенными. Математическим аппаратом для решения такого рода задач является нечеткая логика и теория нечетких множеств.

При решении задачи классификации нечеткие нейронные сети предпочтительны по сравнению с обычными нейронными сетями при наличии пересечения классов, так как поведение таких сетей может быть описано на основе нечетких правил и, таким образом, настроено в нотации этих правил.

Качество функционирования системы принятия решений в значительной степени зависит от содержимого её базы знаний. Исследования проблемы нечеткого моделирования и обеспечения качества базы правил за рубежом ведутся довольно активно, однако, в отечественной литературе они слабо освещены. Среди наиболее известных исследователей следует назвать R. Babushka, M. Delgado, R. Perez, A. Gonzales, M. Sugeno, B. Kosko, B.V. Борисов, В.В. Круглов, А.С. Федулов, Н.Г. Ярушкина.

На сегодняшний день существуют две основные группы методов получения знаний: прямые (интервью, изучение литературы и др.) и косвенные (анализ обучающего множества примеров, наблюдения за экспертом и др.).

Многочисленные проведённые исследования показали, что при принятии решений в условиях неопределённости, то есть при работе со слабоструктурированной, неполной или нечеткой информацией, большую предпочтительность имеют методы второй группы.

В настоящее время существует большое количество различных методов решения задачи классификации, однако изначально количество классов в них задается пользователем, исходя из примерного представления о характере будущего решения. Практически неизвестны методы, в которых помимо решения задачи классификации проводилась бы оценка значимости признаков. Для задач с небольшим количеством примеров (не более 20) и 2 – 3 признаками классификации по данным методам можно провести вычисления вручную. Для задач с большой размерностью данные методы не пригодны.

В исследуемой задаче, как число примеров, так и число признаков достаточно велико, что требует разработки методов и алгоритмов автоматической генерации базы нечетких

правил на основании количественных оценок классифицируемых признаков с выдачей результата в виде совокупности продукционных правил вида "если – то".

В данной работе изначально полагаем, что нечеткие «ЕСЛИ – ТО»-правила, заданные экспертами, уже представлены в лингвистической форме или в виде четкой кластеризации корректных входных – выходных наборов данных. Данная база знаний исследовалась на полноту и минимальность числа правил в работе [2]. На основании полученных результатов были разработаны методы и алгоритмы автоматической генерации базы знаний.

Для использования такой базы знаний в задаче классификации в данной работе модифицируем метод Абе и Лэна, использованный в [3] для решения задачи аппроксимации функций.

В нашем случае каждый испытуемый характеризуется одномерным выходом y и m -мерным входным вектором x , где x - результаты тестирования испытуемого по конкретному фактору, а y - класс принадлежности испытуемого (кандидат полностью соответствует требованиям специальности, в основном отвечает требованиям специальности, частично соответствует, не соответствует).

Запишем задачу в общем виде.

Область, на которой определена переменная y , разделяется на n интервалов и определяется степенью принадлежности кандидата требованиям специальности.

$[y_0, y_1], (y_1, y_2], \dots, (y_{n-1}, y_n]$, где $y_0 = M_1, y_n = M_2$.

Назовем i -й интервал $(y_{i-1}, y_i]$ выходным интервалом i .

Используя заданные выходные данные, для которых выходы находятся в выходном интервале i , необходимо рекурсивно определить область входных значений, соответствующую этому входному интервалу. А именно, прежде всего, надо найти области активизации, определяющие входную область, соответствующую выходному интервалу i , посредством вычисления минимального и максимального значений входных данных. Это необходимо проделать для каждого выходного интервала. Если область активизации для выходного интервала i перекрывается с областью активизации для выходного интервала j , то область перекрытия определяется как область запрещения.

Если входные данные для выходных интервалов i и/или j находятся внутри области запрещения, то определяются одна или две дополнительные области активизации. В дальнейшем если такие дополнительные области активизации также перекрываются, то для них определяется дальнейшая область запрещения. Данный процесс, показанный на рисунке 1, повторяется до тех пор, пока проблема наложения областей не будет решена.

Нечеткие правила определяются на основе полученных областей активизации либо на основе областей активизации и соответствующих областей запрещения (если они сгенерированы).

Рассмотрим алгоритм, с помощью которого вычисляются нечеткие степени принадлежности входных данных к соответствующим выходным интервалам с последующим приведением к четкому значению.

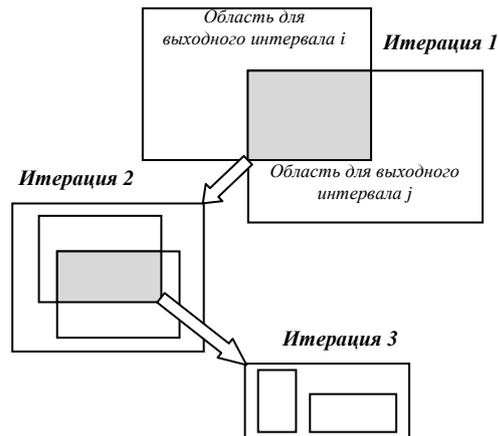


Рисунок 1 – Рекурсивное определение областей активизации и запрещения

В начале работы алгоритма реализуются нечеткие правила «ЕСЛИ–ТО», вычисляющие степени принадлежности переменных входного вектора x .

На втором этапе рассчитываются максимальные значения выходов элементов первого этапа, которые представляют собой степени принадлежности, полученные в результате ликвидации перекрытий между парой выходных интервалов. Число элементов для выходного интервала i определяется по числу выходных интервалов, чьи входные пространства перекрываются со входным пространством данного выходного интервала i . Поэтому, если изначально нет перекрытия между входными пространствами выходного интервала i и какого-либо другого выходного интервала, то в алгоритме для выходного интервала i этот и последующие этапы отсутствуют.

На третьем этапе для выходного интервала i определяет минимальное значение среди максимальных значений, найденных ранее и соответствующих перекрытию между двумя выходными интервалами. Поэтому если выходной интервал i изначально перекрывается только с одним выходным интервалом, то в алгоритме для выходного интервала i этот этап отсутствует. Таким образом, данный алгоритм в процессе образования входных областей позволяет избавиться от перекрытия между интервалами.

Данный подход позволяет сформировать начальную базу правил и оптимизировать ее в ходе работы с данными. В автоматически сформированной таким образом базе продукционных правил контролируется ее полнота и непротиворечивость, что приводит к улучшению механизмов нечеткого логического вывода. Структуризация такой базы знаний позволяет повысить качество и эффективность систем принятия решения, а, именно, увеличить скорость обучения сети и ее точность.

Содержимое сформированной базы знаний подается в нейронную сеть в качестве обучающей выборки. Входной вектор сети состоит из результатов тестирования конкретного испытуемого, а класс принадлежности кандидата к определенной специальности является выходом сети.

Для реализации интеллектуальной поддержки системы принятия решений разработана модель гибридного нейронечеткого классификатора и нечеткого многослойного персептрона.

Структура гибридного нейронечеткого классификатора представлена на рисунке 2 [3].

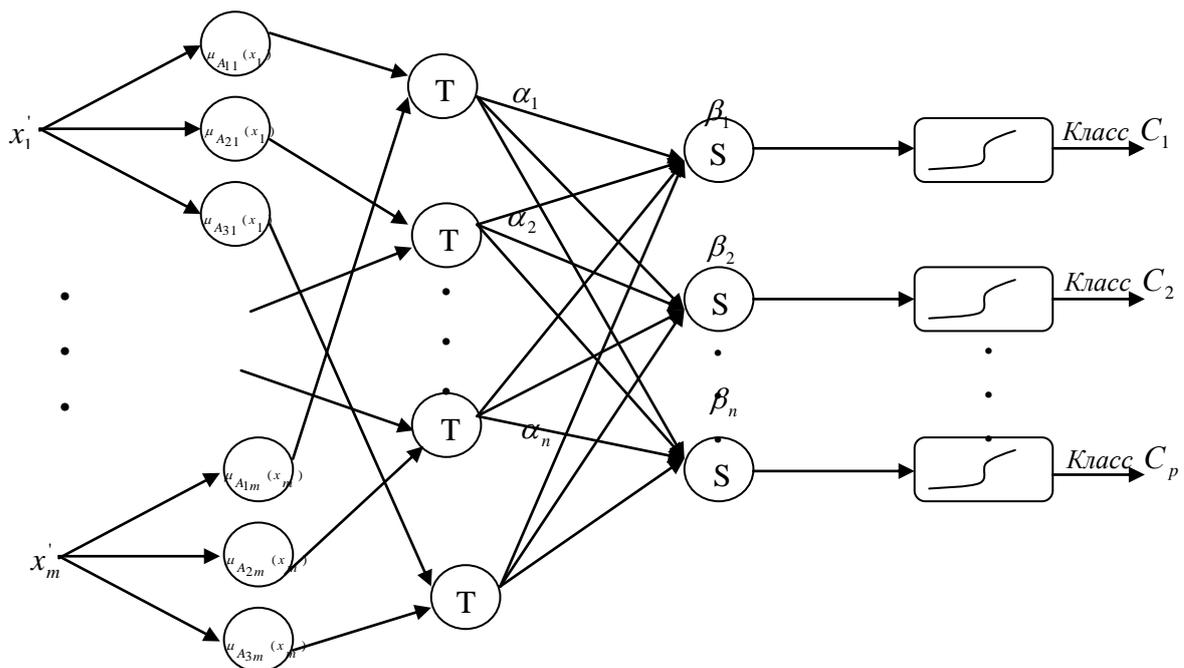


Рисунок 2 – Структура гибридного нейронечеткого классификатора

Нейронечёткая сеть состоит из четырёх слоёв.

Элементы первого слоя реализуют операцию фуззификации, то есть формируют степени принадлежности входных переменных к определенным для них нечетким множествам A_{ij} :

$$\mu_{A_j}(x'_j) = \exp \left[-\frac{1}{2} \left(\frac{x'_j - c_{ij}}{\sigma_{ij}} \right)^2 \right],$$

где c_{ij}, σ_{ij} – параметры функции принадлежности колоколообразного типа.

Начальные значения этих параметров установлены таким образом, чтобы функции принадлежности удовлетворяли свойствам полноты, нормальности и выпуклости. Значения c_{ij} должны быть равномерно распределены в области входных векторов x . Значения данных параметров корректируются в процессе обучения сети, основанном на градиентном методе.

Каждый элемент второго слоя является нейроном «И». Они выполняют агрегирование степеней истинности предпосылок каждого правила базы в соответствии с операцией T -нормы по формулам:

$$\begin{aligned} \alpha_1 &= \min\{A_{11}(x_1), A_{12}(x_2), \dots, A_{1n}(x_n)\}; \\ \alpha_2 &= \min\{A_{21}(x_1), A_{22}(x_2), \dots, A_{2n}(x_n)\}; \\ &\dots \\ \alpha_n &= \min\{A_{n1}(x_1), A_{n2}(x_2), \dots, A_{nn}(x_n)\}. \end{aligned}$$

Элементы третьего слоя выполняют нормализацию и вычисляют следующие значения:

$$\begin{aligned} \beta_1 &= \frac{\alpha_1}{\alpha_1 + \alpha_2 + \dots + \alpha_n}; \\ \beta_2 &= \frac{\alpha_2}{\alpha_1 + \alpha_2 + \dots + \alpha_n}; \\ &\dots \\ \beta_n &= \frac{\alpha_n}{\alpha_1 + \alpha_2 + \dots + \alpha_n}. \end{aligned}$$

Элементы четвертого слоя вычисляют значения заключений по каждому правилу:

$$\begin{aligned} y'_1 &= B_1^{-1}(\alpha_1) = a_1 + \frac{1}{b_1} \ln \frac{1 - \alpha_1}{\alpha_1}; \\ y'_2 &= B_2^{-1}(\alpha_2) = a_2 + \frac{1}{b_2} \ln \frac{1 - \alpha_2}{\alpha_2}; \\ &\dots \\ y'_n &= B_n^{-1}(\alpha_n) = a_n + \frac{1}{b_n} \ln \frac{1 - \alpha_n}{\alpha_n}, \end{aligned}$$

где a_i, b_i – нелинейные параметры функций принадлежности $\mu_{B_i}(y)$ нечетких множеств заключений правил.

Выходы нечеткой сети вычисляются следующим образом: $y'_i = \beta_i B_i^{-1}(\alpha_i)$.

Эти выходы трактуются как степени принадлежности предъявленного объекта соответствующему классу.

На рисунке 3 приведена структура нечеткого многослойного персептрона. Он состоит из двух частей: нейронов «нечеткого слоя» и собственно многослойного персептрона. Функции активации нейронов «нечеткого слоя» такой сети являются радиальными базисными функциями (в виде функции Гаусса), моделирующими функции принадлежности. Эти нейроны предназначены для определения степеней принадлежности компонентов входных векторов (которые могут быть и нечеткими). На выходах нейронов этого слоя формируются коэффициенты в требуемой для дальнейшего распознавания форме. Выходы нейронов «нечеткого слоя» употребляются в качестве входов традиционного многослойного персептрона.

Если на вход сети подается $x = [x_1, x_2, \dots, x_m]^T$, то на выходе «нечеткого слоя» формируется вектор, состоящий из степеней принадлежности x к конкретным центрам (радиально базисным функциям); $\mu(x) = [\mu_1(x), \mu_2(x), \dots, \mu_m(x)]^T$. Конкретные компоненты вектора рассчитываются таким образом, чтобы удовлетворять условию нормализации $\sum_{i=1}^L \mu_i(x^{(k)}) = 1$ для каждого вектора $x^k, k = 1, \dots, K$, где K – число векторов в обучающей выборке.

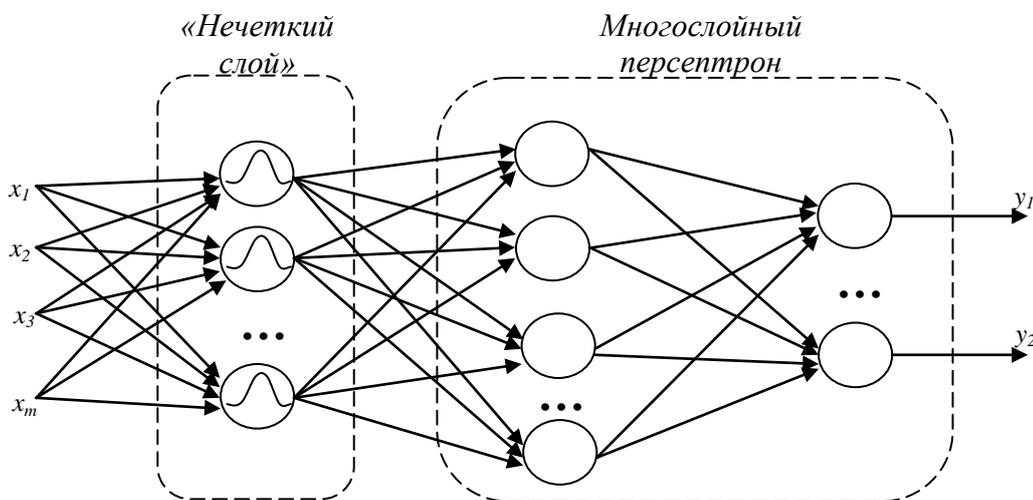


Рисунок 3 – Структура нечеткого многослойного персептрона

В модели нечеткого многослойного персептрона присутствуют следующие операторы [3]:

1. оператор для формирования степени принадлежности входных переменных к определенным для них нечетким множествам:

$$\mu_1(x^{(k)}) = 0.5 + \frac{\exp(f(p_2 - p_1)/p_{med}) - \exp(-f)}{2(\exp(f) - \exp(-f))}, \text{ где } f - \text{ константа, подбираемая опытным}$$

$$\mu_2(x^{(k)}) = 1 - \mu_1(x^{(k)}),$$

путем ($f > 0$); p_2 – расстояние от вектора $x^{(k)}$ до центра класса 2; p_1 – расстояние от вектора $x^{(k)}$ до центра класса 1 в соответствии с выбранной метрикой (например, евклидовой); p_{med} – расстояние между центрами классов 1 и 2;

2. оператор логического произведения для агрегации условия нечеткого правила относительно классифицируемого образа.

Выходы нечёткого многослойного персептрона трактуются как степени принадлежности предъявленного объекта соответствующему классу.

В данных нейронечетких сетях используется алгоритм Цукомото, а в качестве алгоритма обучения реализован метод обратного распространения ошибки.

В результате проведенного исследования качества работы построенных сетей в роле универсального классификатора выявлено влияние параметров гибридного нейронечёткого классификатора (объема обучающей выборки, шага обучения сети, вида функции фуззификации и метода дефуззификации) так и нечёткого многослойного персептрона (объема обучающей выборки, шага обучения сети, вида функции фуззификации и количества нейронов в скрытом слое) на скорость их обучения. Данные результаты можно резюмировать следующим образом:

1) Обучающая выборка большой размерности не ведет к улучшению качества обучения нейронной сети, а лишь вызывает ее нечувствительность к избыточным данным. Для данной задачи оптимум достигается при объеме обучающей выборки, равном 100 примерам. Однако, если количество обучающих примеров ограничено, то необходимо для обучения сети использовать выборку из 33 примеров.

2) Быстрое обучение сети увеличивает риск отклонения от решения с последующими осцилляциями вокруг него. Низкие значения шага обучения устраняют эту проблему, приводя к замедлению процесса обучения сети. Для данной задачи в обоих сетях шаг 0,45 является оптимальным.

3) Обучение гибридного нейронечёткого классификатора с гауссовской функцией фуззификации происходит быстрее, чем его модификации с треугольной функцией. Однако, в последнем случае алгоритм обучения сети значительно упрощается за счет более простого вида самой функции фуззификации, благодаря чему система ведет себя более предсказуемо.

4) Обучение нечёткого многослойного персептрона с функцией гиперболического тангенса происходит быстрее, чем его модификации с логистической функцией фуззификации. Однако, если длительность обучения сети не имеет принципиального значения, целесообразно использовать нечёткий многослойный персептрон с логистической функцией фуззификации, т.к. в этом случае система ведет себя более предсказуемо.

5) С увеличением количества нейронов в скрытом слое нечёткий многослойный персептрон быстрее обучается до заданного допустимого порога ошибки. В данной задаче при оптимальном шаге число нейронов следует выбирать от 35 до 40.

6) Вид метода дефуззификации не влияет на СКО и скорость обучения гибридного нейронечёткого классификатора.

7) Гибридный нейронечёткий классификатор обладает быстрым алгоритмом обучения сети и хорошую интерпретируемость накопленных знаний

8) Нечёткий многослойный персептрон закономерно ведет себя на всем этапе обучения сети.

Далее приведем сравнительный анализ построенных нейронечётких классификаторов (таблицы № 1 – 2). Для решения исходной задачи классификации кандидатов на конкретную должность на основе анализа их профессиональной пригодности целесообразней использовать гибридный нейронечёткий классификатор, так как он имеет быстрый алгоритм обучения сети и хорошую интерпретируемость накопленных знаний, что удобно при решении прикладных задач.

Таблица 1

Результаты классифицирующих свойств гибридного нейронечеткого классификатора

Функция фуззификации	Метод дефуззификации	Погрешность классификации, %
гауссовская	минимальное отклонение	94
	СКО	99
	Максимальное отклонение	93
треугольная	минимальное отклонение	88
	СКО	97
	Максимальное отклонение	93

Таблица 2

Результаты классифицирующих свойств нечеткого многослойного персептрона

Функция фуззификации	Погрешность классификации, %
логистическая	96
гипербалического тангенса	83

Модернизированная структура гибридного нейронечеткого классификатора и алгоритм его обучения позволяют с помощью такой сети решить задачу прогнозирования, например, прогнозирование успешности профессионала. При обычном подходе в данном случае необходимо множество замеров индивидуальных показателей, динамика которых позволила бы построить тренд, но в реальной практике управления персоналом это невозможно. Однако предложенная выше нейронная сеть способна осуществлять данные прогнозы, после обучения на множестве примеров.

Таким образом, в данной работе предложен метод и алгоритм автоматической генерации базы знаний в соответствии с требованиями предметной области, разработаны модели нейронечетких сетей для решения задачи поддержки принятия решений в системах управления кадров на основе психодиагностики.

Практическая ценность работы заключается в разработке алгоритмического и программного обеспечения автоматизированного программного комплекса интеллектуальной поддержки принятия решений в системах управления кадрами, позволяющего решать следующие задачи:

1. поддержка принятия решений о соответствии кандидата требованиям специальности;
2. ротация сотрудников и перераспределение функциональных обязанностей внутри коллектива предприятия;
3. многофакторная диагностика профессионально значимых качеств личности на основе интерактивного перечня требований к профессии;
4. прогнозирование успешности профессионала.

Библиографический список

1. Зиновьев А.Ю. Визуализация многомерных данных – http://www.koob.ru/zinovyevev_andrey/vizualizaciya_dannih
2. Новак В., Перфильева И., Мочкорж И. Математические принципы нечеткой логики – М.: Физматлит, 2006.
3. Борисов В.В., Круглов В.В., Федулов А.С. Нечёткие модели и сети – М.: Горячая линия– Телеком, 2007.

Сведения об авторах

Даниленко Александра Николаевна; аспирант «Самарского государственного аэрокосмического университета имени академика С.П. Королева (национальный исследовательский университет)»; тел. 7(905)302-39-58, e-mail: danilenko.al@gmail.com.