

УДК 519.71

Д.П. Димитриченко, Р.А. Жилов

ПРИМЕНЕНИЕ НЕЙРОСЕТЕВОГО ПОДХОДА К ЗАДАЧАМ ЛОГИЧЕСКОЙ ОБРАБОТКИ ДАННЫХ И ПОСТРОЕНИЕ ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМ ПРИНЯТИЯ РЕШЕНИЙ

*Институт прикладной математики и автоматизации – филиал
Федерального государственного бюджетного научного учреждения
«Федеральный научный центр «Кабардино-Балкарский научный центр
Российской академии наук»*

Необходимость уменьшения размерности больших массивов данных при сохранении логической структуры, а также, выявление скрытых закономерностей и удаление информационных шумов и избыточности в описании объектов диагностики (распознавания) приводит к необходимости построения эффективного метода классификации объектов в слабо формализуемых областях знаний. Логические функции, описывающие объекты при помощи переменных предикатов, позволяют выявить скрытые закономерности и устранить избыточность в описании объектов. Упорядоченные при помощи переменных логических функции классы объектов являются основой для формирования структуры когнитивных карт. Целью настоящего исследования является создание алгоритма для построения логической нейронной сети на основе переменных логической функции и обоснование возможности применения полученных результатов при построении когнитивных карт. Обоснована теоретическая возможность и приведены алгоритмы, позволяющие осуществить переход от переменных логических функций к когнитивным картам при помощи нейросетевого подхода. Результатом данной работы является процедура построения когнитивной карты с применением логических нейронных сетей, построенных на основе переменных логических функций. Преимуществом полученной когнитивной карты является возможность функционирования в рамках нечеткой логики.

Ключевые слова: предикат, значность предиката, переменная логическая функция, логическая нейронная сеть, когнитивная карта, кластерный анализ, нейронная сеть.

1. Введение

Одним из известных направлений уменьшения внутренней размерности данных является кластеризация данных. Кластерный анализ позволяет разбивать множество входных данных на конечное число однородных групп: кластеров. Кластеризация находит широкое применение при построении когнитивных карт. [1,2]

Целью настоящего исследования является обоснование метода построения когнитивных карт, предназначенных для классификации объектов из заданного множества W на основе подклассов, выявленных при помощи переменных логических функций.

Предложенный в [3] логический алгоритм построения переменных функций, устраняющий избыточность в описании

данных и выделяющий наиболее важные причинно-следственные связи в описании объектов, позволяет успешно решать задачу оптимального описания объектов и производить формирование всех возможных подклассов, объединяющих объекты по выявленным наборам характеристик.

Первоначально задаваемые объекты и их характеристики структурируются в виде продукционных правил, в каждом из которых объект является следствием характеризующих его свойств [4].

2. Общая постановка задачи

Приведем общую постановку задачи [4]:

Пусть $W = \{w_1, \dots, w_m\}$ - заданное множество объектов, образующих обучающую выборку (ОВ). Описание объекта, принадлежащих ОВ W , представляет собой n -компонентный вектор, где n - число признаков, используемых для характеристики анализируемого объекта, причем j -я координата этого вектора равна значению j -го признака, $j=1, \dots, n$. Число таких векторов равно m по числу анализируемых объектов, входящих в ОВ W . Соответствие множества объектов и характеризующих их признаков представима в виде следующей таблицы:

Таблица 1. Входные данные.

| x_1 x_2 ... x_n | W |
|--------------------------------------|-------|
| $x_1(w_1)$ $x_2(w_1)$... $x_n(w_1)$ | w_1 |
| $x_1(w_2)$ $x_2(w_2)$ | w_2 |
| $x_n(w_2)$ | ... |
| | w_m |
| $x_1(w_m)$ $x_2(w_m)$ | |
| $x_n(w_m)$ | |

$$X_j = \{x_1(w_j), x_2(w_j), \dots, x_n(w_j)\}$$

X -вектор качественных признаков, каждый элемент которого фиксированный признак характеризующего объекта.

$$W = \bigcup_{j=1}^m w_j$$

W - множество характеризующих объектов.

Каждый соответствующий признак $x_j(w_i)$ кодируется переменным предикатом значности $k_j, j = 1, \dots, n$.

$$f(x) = \bigwedge_{j=1}^m (\bigwedge_{i=1}^n x_i(w_j) \rightarrow w_j) = \bigwedge_{j=1}^m (\bigvee_{i=1}^n \overline{x_i(w_j)} \vee w_j)$$

Указанный вид функции следует из известного логического тождества: $a \rightarrow b = \bar{a} \vee b$, где a конъюнкция характеристик (признаков), определяющих объект, а b — предикат, равный единице, когда w_j становится равным соответствующему определяемому объекту. Такие предикаты будем называть объектными предикатами.

Поскольку очень часто эксперту приходится иметь дело с разнородным набором параметров (характеристик) исследуемых объектов, то переменнзначные предикаты как нельзя лучше подходят для наиболее адекватного кодирования свойств (признаков) анализируемых объектов, подбирая для каждого из них свою индивидуальную шкалу значений. Например, двузначный предикат, заданный на множестве значений «0» и «1» в состоянии кодировать наличие (или отсутствие) у анализируемого объекта некоторого свойства (характеристики). А трехзначный предикат, заданный на наборе свойств «холодно», «тепло», «жарко» способен легко кодировать общее представление об окружающей (или внутренней) диагностируемой температуре объекта.

Совокупность объектов и характеризующих их свойств (признаков), представленную в приведенной выше таблице легко преобразовать в логическую систему продукционных правил. Такая логическая система продукционных правил является основой для построения переменнзначной логической функции. Эта совокупность продукционных правил при помощи логических операций представима в следующем виде:

(Конъюнкция признаков 1 \rightarrow Объект₁),
(Конъюнкция_признаков_2 \rightarrow Объект₂),
...
(Конъюнкция признаков_m \rightarrow Объект_m).

Совокупность из m продукционных правил при помощи $m-1$ операции конъюнкции связывается в одно высказывание, порождающее переменнзначную логическую функцию $F(X, W)$. Эта функция с учетом предложенной в [3] операции обобщенного отрицания представима в виде КНФ. Последовательное раскрытие m скобок приводит к построению переменнзначной логической функции $F(X, W)$ в виде ДНФ, где X - n -компонентный вектор логических переменных (переменнзначных предикатов), кодирующий всю совокупность признаков объектов, принадлежащих ОБ W : $X=x_1, x_2, \dots, x_n$, а $W=w_1, \dots, w_m$ — множество объектов, принадлежащих ОБ, мощности m .

В результате этого преобразования функция $F(X, W)$, принимает вид дизъюнкции, включающей в себя все возможные подклассы объектов,

представляющих собой конъюнкцию только тех объектов и признаков по которым эти объекты совпадают, тем самым формируя соответствующие подклассы с различными степенями близости.

При нахождении значения логической функции $F(X, W)$ от заданного набора характеристик X^* в качестве итогового результата формируется дизъюнкция тех подклассов объектов из множества W , значения переменных при которых совпадают со значениями переменных в заданном наборе запроса X^* . При этом, чем большему числу переменных из запроса X^* соответствует объект w^* , принадлежащий W , тем большее число подклассов с его участием будет присутствовать в результирующем множестве W^* : $W^* = F(X^*, W)$. Отсюда следует, что для выявления наилучшего объекта, наиболее полно удовлетворяющего запросу X^* , достаточно к получившейся совокупности подклассов W^* применить процедуру частотного анализа.

Заметим, что при большом количестве входящих в ОВ объектов и характеризующих их признаков логические вычисления, связанные с построением переменнзначной логической функции и нахождением ее значений становятся достаточно трудоемкими, так как число различных образуемых подклассов в общем виде растет экспоненциально. В этой связи представляет интерес возможность распараллеливания вычислительного процесса. Широкоизвестным методом для решения интеллектуальных задач и организации распределенных вычислений является нейронные сети [5-7]. Замена переменнзначной логической функции эквивалентной ей логической нейронной сетью позволит решить эту задачу.

3. Логические нейронные сети.

В работе [8] был предложен схемотехнический подход для построения логической нейронной сети. С этой целью в качестве обучающей выборки формируется система причинно-следственных связей между поступающими на входной слой нейронной сети совокупностями входных сигналов и принимаемыми решениями. В этом случае интеллектуальная система принятия решений представляет собой следующую систему имплицативных высказываний:

Совокупность_сигналов_1 \rightarrow Решение_1,

Совокупность_сигналов_2 \rightarrow Решение_2,

...

Совокупность_сигналов_m \rightarrow Решение_m.

Пусть R - множество таких решений мощности m , $R = r_1, \dots, r_m$.

Заметим, что в общем случае одно и то же решение r_i может следовать из различных совокупностей входных сигналов x^* .

Вычисления в каждом из m импликативных высказываний производятся параллельно в соответствии с особенностями функционирования нейронной сети. В качестве выходного результата формируется множество четко (или нечетко) взвешенных решений.

Особенность схемотехнического подхода состоит в том, что логическая нейронная сеть рассматривается как сложное логическое высказывание, включающее в себя переменные и константы, связанные операциями конъюнкции и дизъюнкции. При этом, логические операции реализуются при помощи особых нейроэлементов.

Для построения логической нейронной сети вводятся два типа нейронов: конъюнкторы и дизъюнкторы. Веса входных сигналов этих нейронов устанавливаются таким образом, чтобы при четких значениях входных сигналов на выходе этих нейронов вырабатывались бы совокупности результирующих сигналов, соответствующие значениям логических операций конъюнкции и дизъюнкции. Например, веса входов конъюнктора с n входами устанавливаются равными $1/n$. Таким образом, на выходе конъюнктора логическая единица будет генерироваться только тогда, когда все входы такого нейрона равны единице. Веса всех входов дизъюнктора устанавливаются достаточно близкими к единице, так чтобы для генерации логической единицы на выходе такого нейрона достаточно было бы присутствия хотя бы одной единицы на его входах.

Мы видим, что, с одной стороны, операции конъюнкции и дизъюнкции реализуются при помощи соответствующих нейроэлементов, а, с другой стороны, построение переменных логических функций так и логических нейронных сетей связано с начальной совокупностью продукционных (импликативных) правил.

Это, в свою очередь, позволяет говорить о теоретически обоснованном переходе от заданной переменных логической функции к соответствующей ей логической нейронной сети. Алгоритм построения основан на приведенной ниже теореме.

4. Построение переменных логической нейронной сети

Мы видим, что одна и та же система продукционных правил (импликативных высказываний) является основой для построения как переменных логических функций, так и логических нейронных сетей, обученных для работы с соответствующей базой знаний. [9,10]

Опираясь на метод биективного доказательства сформулируем следующую теорему:

Теорема 1. Всякая переменнзначная логическая функция $F(X,W)$ представима в виде логической нейронной сети, совокупность логических связей в которой взаимно однозначно определяется структурой продукционных дизъюнктов.

Доказательство содержит и алгоритм построения логической нейронной сети по заданной переменнзначной логической функции $F(X,W)$, который состоит из следующих шагов:

Построить входной слой в соответствии с количеством n и качеством, т.е. совокупностью значностей k_j значностей переменнзначных предикатов $X=x_1, \dots, x_n, j=1, \dots, n$;

Построить выходной слой в соответствии с совокупностью объектов (выходных решений), содержащихся во множестве $W=w_1, \dots, w_m$, где m – мощность множества анализируемых объектов W ;

Для каждого из входящих в переменнзначную логическую функцию $F(X,W)$ продукционных дизъюнктов построить соответствующий ему конъюнктор;

Построить дизъюнктор, суммирующий результаты работы (объединяющий выходы) всех полученных конъюнкторов.

Таким образом, переменнзначная логическая функция $F(X,W)$ представима в виде трехслойной нейронной сети, для которой:

В качестве входного слоя выступают предикаты x_j значности k_j , каждый, $j=1, \dots, n$.

В качестве выходного слоя, производящего окончательные вычисления, выступает множество объектов или выходных сигналов $W = \{w_1, w_2, \dots, w_m\}$.

В качестве скрытого слоя, производящего промежуточные вычисления, выступают продукционные дизъюнкты, в которых операции конъюнкции и дизъюнкции заменены нейронами конъюнкторами и дизъюнкторами.

Свободным знаниям переменнзначной логической функции соответствуют такие наборы входных сигналов логической нейронной сети, которым не сопоставлены ни какие выходные сигналы.

Будут или нет свободные знания в явном виде содержаться в структуре логической нейронной сети зависит от специфики решаемой задачи. Более подробно этот вопрос рассмотрен ниже следующем пункте.

Если на вход построенной таким образом нейронной сети подать значения логических переменных в соответствии с некоторым запросом x^* , то на выходе будет получена совокупность объектов, удовлетворяющих этому запросу, веса которых в точности совпадают с

результатом работы процедуры частотного анализа, применяемой для нахождения объектов, наиболее полно соответствующих запросу X^* , при вычислении значения переменнзначной логической функции $F(X,W)$: $W^* = F(X^*,W)$ [4].

Наличие в результирующем ответе свободных знаний говорит о том, что не все значения из совокупности запрашиваемых характеристик X^* могут быть проинтерпретированы с учетом текущей на момент запроса ОБ. Учет этого фактора позволил бы рассчитывать коэффициент «уверенности распознавания» запрашиваемого объекта, так как, чем меньшее число характеристик из запроса X^* участвуют в получении результирующего ответа, тем менее полным окажется найденный результат. С этой целью строится расширенная логическая нейронная сеть.

5. Расширенная логическая нейронная сеть

Теперь включим в логическую нейронную сеть фактор наличия в структуре переменнзначной логической функции $F(X,W)$ дизъюнктов свободных знаний. Это такие совокупности наборов свойств, которым в исходной ОБ W не сопоставлены ни какие объекты. Как отмечалось выше, наличие в окончательном ответе свободных знаний при вычислении переменнзначной логической функции $F(X,W)$ указывает на то, что по этим свойствам (и их сочетаниям) в исходной ОБ W отсутствуют объекты, этими свойствами обладающие. Учет фактора свободных знаний предоставит лицу, принимающему решение, дополнительную информацию о степени несоответствия части (или всей совокупности) свойств запроса X^* множеству свойств по которым объекты в ОБ W определены.

Для учета фактора свободных знаний добавим во множество выходных решений логической нейронной сети эквивалентное множеству W еще один дополнительный элемент: w_0 . Это элемент, обозначающий фиктивный объект, неопределенный объект ОБ W , который не обладает ни какими свойствами из множества переменнзначных предикатов X . Теперь в выходном множестве решений формируемой логической нейронной сети, включая w_0 , содержатся $m+1$ элементов. Дополним множество продукционных конъюнктов логической нейронной сети, связанных с выявленными подклассами, дополнительными конъюнктами, соответствующими свободным знаниям. Выходы всех этих дополнительных конъюнктов, отражающих структуру свободных знаний, свяжем с элементом, обозначающим фиктивный, неопределенный объект w_0 . Таким образом, появление хотя бы одного элемента из множества свободных знаний при обработке запроса X^* проинформирует

лицо, принимающее решение, о невозможности обработки запроса X^* по всем n свойствам. С другой стороны, элемент w_0 можно рассматривать как степень «неуверенности» нейронной сети при распознавании объектов из множества W , или как степень неполноты накопленных нейронной сетью знаний по отношению к запросу X^* . Определенное значение веса элемента w_0 в выходном результате может сигнализировать о необходимости процесса дообучения.

Такую логическую нейронную сеть с учетом добавленного неопределенного объекта w_0 и множества конъюнктов, соответствующих свободным знаниям мы будем называть расширенной логической нейронной сетью.

Очевидно, что результаты доказательства теоремы 1, а также способ ее доказательства и алгоритм построения логической нейронной сети можно целиком перенести на случай расширенной логической нейронной сети, внося в них некоторые изменения.

Теорема 2. Всякая переменнзначная логическая функция $F(X,W)$ представима в виде логической нейронной сети, совокупность логических связей в которой взаимно однозначно определяется структурой продукционных дизъюнктов и дизъюнктов свободных знаний.

Появление в окончательном ответе расширенной логической нейронной сети элемента w_0 с некоторым ненулевым коэффициентом предоставит лицу, принимающему решение, информацию о степени неполноты совокупности заключенных в структуре логической нейронной сети знаний (продукционных правил) при обработке запроса X^* . Эта информация, например, может послужить сигналом к началу процесса дообучения логической нейронной сети, пополнения текущей системы знаний новыми продукционными правилами.

Как отмечалось выше, переменнзначная логическая функция $F(X,W)$ на основе исходной ОБ W формирует множество подклассов, объединяющих объекты по одной и более характеристик из множества свойств X .

В соответствии с приведенными выше теоремами, любая переменнзначная логическая функция представима в виде соответствующей ей логической нейронной сети.

Так как такая логическая нейронная сеть содержит все выявленные подклассы объектов из множества W , то она может быть применена в процедурах построения когнитивных карт.

6. Построение когнитивных карт при помощи логических нейронных сетей

Когнитивная карта представляет собой оргграф $G := (K, w)$, где K -множество вершин графа – концепты: компоненты рассматриваемой динамической системы или наблюдаемые факторы исследуемой предметной области, а w -множество ребер – совокупность взаимосвязей, выявленных (или допускаемых с некоторой степенью правдоподобия) между концептами.

При этом, когнитивная карта строится не на неупорядоченных входных данных, а на k , где $k < n$. Иными словами, для построения когнитивной карты используются не «сырые», а кластеризованные данные. В силу производимой кластеризации происходит фактическое уменьшение объема действительно существенных для целей анализа данных, избавление от шумов и дублируемой (близкой по фактическому наполнению входной информации, что приводит к уменьшению количество концептов (найденных кластеров) и к выявлению действительно существенных взаимосвязей между этими концептами. Такой подход, с одной стороны, позволяет сократить количество производимых вычислительной средой операций на каждом шаге алгоритма по обработке когнитивной карты. С другой стороны, когнитивная карта, как модель представления исследуемой предметной области в виде выявленных объектов (кластеров) и факторов (связей между ними) становится более наглядной и понятной лицу, принимающему решение. Эти обстоятельства облегчают построение когнитивных карт, работающих в реальном режиме времени.

Выявленные кластеры служат основой для построения множества концептов. Первоначально характер и значения весов связей влияния задаются экспертом (или группой экспертов), что существенно увеличивает долю субъективизма в когнитивной карте.

После того, как когнитивная карта построена, производится ее параметризация, т.е. дальнейшая оптимизация весов связей, заключающаяся в настройке весов влияния концептов друг на друга, которая, как правило, проводится при помощи методов машинного обучения. [11]

Применение нейросетевого подхода к решению задачи оптимизации весов связей когнитивной карты исследуемой предметной области оказывается очень плодотворным.

В процессе оптимизации построенная нейронная сеть формирует выходной вектор u в соответствии с входным вектором x . Веса связей

подстраиваются в зависимости от того, насколько отличается полученный результат от желаемого.

Такая процедура оптимизирует веса связей когнитивной карты для последующего прогнозирования динамики исследуемой системы. Единственным условием для корректной подстройки весов является наличие обучающей выборки (данные функционирования системы по которой строится когнитивная карта за предыдущие этапы времени).

Пусть R - количество концептов оптимизируемой (настраиваемой) когнитивной карты.

Пусть также каждый из концептов способен пребывать в одном из k_r состояний, $k_r \geq 2, r=1, \dots, R$.

Пусть X - вектор входных параметров (текущих состояний концептов). При этом, значность предиката x_r равна $k_r, r=1, \dots, R$.

Пусть также для каждого из R концептов (при помощи экспертов) составлена система известных правил смены состояний этого концепта в зависимости от состояния окружающей среды X и состояний других $R-1$ концептов. Совокупность таких правил может быть представлена в логической форме при помощи системы продукционных правил. А система продукционных правил путем логических вычислений приводится к виду переменнзначной логической функции $F(X, W_r)$, где W_r - множество состояний концепта $r=1, \dots, R$.

Учитывая, что вектор X отражает совокупность состояний всех R концептов, то вычисление каждой из R переменнзначных логических функций $F(X^*, W_r)$ от значений X^* текущих состояний концептов даст R значений концептов на следующем шаге. Выполняя последовательно эти вычисления можно пронаблюдать поведение когнитивной карты за исследуемый период времени (за заданное число шагов).

В соответствии с доказанными теоремами все R концептов, представленные в виде R переменнзначных логических функций взаимно-однозначным образом преобразуются в соответствующие им логические нейронные сети. А объединение R концептов, представленных в виде R логических нейронных сетей в один нейромодуль даст функциональную и логическую схему когнитивной карты в целом. При этом, требуются совершенно незначительные изменения, чтобы построить нечеткую когнитивную карту на основе логической нейронной сети с нечеткой логикой.

Таким образом, построение ОВ W исследуемой предметной области при помощи продукционных правил на основе переменнзначных предикатов позволяет построить когнитивную карту (в рамках четкой или

нечеткой логики) в виде логического нейромодуля, не прибегая к итерационной процедуре обучения нейронной сети.

7. Заключение

Мы видим, что построение и применение переменных логических нейронных сетей позволяет не только сохранить свойства переменных логических функций, но и расширить область их применения. Предложен алгоритм построения логической нейронной сети на основе переменных логических функций.

Построенная нейронная сеть сохраняет всю систему начальных продукционных правил и подклассов объектов, получаемых в результате удаления избыточной информации из начальной системы правил путем применения логических операций и построения логической базы знаний.

Показана возможность применения полученных результатов для построения когнитивных карт, производящих вычисления в рамках четкой и нечеткой логик.

Работа выполнена при финансовой поддержке РФФИ (проект № 18-01-00050-а).

ЛИТЕРАТУРА

1. Axelrod R., The structure of Decision: Cognitive Maps of Political Elites. Princeton University Press, 1976. — 321 с.
2. Carvahlo J.P., Tome J.A.B., Rule Based Cognitive Maps — A comparison with fuzzy Cognitive Maps//Proceedings of the NAFIPS99, 1999. — 32 с.
3. Лютикова Л.А., Тимофеев А.В., Стурев В.В., Йоцов В.И Развитие и применение многозначных логик и сетевых потоков в интеллектуальных системах. // Труды СПИИРАН, вып. 2, 2005. С. 114–126.
4. Лютикова Л.А. Моделирование и минимизация баз знаний в терминах многозначной логики предикатов. Нальчик. – Препринт, 2006. 33 с.
5. Тимофеев А.В., Косовская Т.М. Нейросетевые методы логического описания и распознавания сложных образов // Труды СПИИРАН. 2013. Вып. 27. С. 144-155.
6. Шибзухов З.М. Конструктивные методы обучения нейронных сетей. М.: Наука, 2006. 159 с.
7. Jürgen Schmidhuber Deep learning in neural networks: An overview Neural Networks Volume 61, January 2015, Pages 85–117
8. Барский А.Б. Логические нейронные сети. ИНТУИТ; БИНОМ, 2007. 352 с.

9. Димитриченко Д. П. Применение переменных логических функций и нейронных сетей в системах принятия решений // Вестник КРАУНЦ. Физ.-мат. науки. 2016. № 4-1(16). С. 93-100.
10. Димитриченко Д.П. Использование нейронных сетей для повышения эффективности переменных логических функций // Вестник ИрГТУ. №10 (105), 2015. С. 12-16.
11. Жилов Р.А., Оптимизация когнитивной карты для задач прогнозирования. // Кибернетика и программирование. 2015. № 5. С.128-135

D.P. Dimitrichenko, R.A. Zhilov
**APPLICATION OF A NEURO NETWORK APPROACH TO
LOGICAL DATA PROBLEMS AND BUILDING INTELLIGENT
DECISION-MAKING SYSTEMS**

*Institute of Applied Mathematics and Automation - branch of the Federal
State Budget Scientific Institution "Federal Scientific Center" Kabardino-
Balkarian Scientific Center of the Russian Academy of Sciences"*

The need to reduce the dimensionality of large data sets while maintaining the logical structure, as well as the detection of hidden patterns and the removal of information noise and redundancy in the description of diagnostic (recognition) objects leads to the need to construct an effective method for classifying objects in weakly formalized areas of knowledge. Logical functions that describe objects using variable-valued predicates allow us to reveal hidden regularities and eliminate redundancy in the description of objects. Ordered by means of variable-valued logical functions, object classes are the basis for the formation of the structure of cognitive maps. The purpose of this study is to create an algorithm for constructing a logical neural network based on the variable-valued logic function and justifying the possibility of applying the results obtained in the construction of cognitive maps. The theoretical possibility and algorithms allowing to make the transition from variable-valued logic functions to cognitive maps using the neural network approach are grounded. The result of this work is the procedure for constructing a cognitive map using logical neural networks built on the basis of variable-valued logical functions. The advantage of the obtained cognitive map is the possibility of functioning within the framework of fuzzy logic.

Keywords: predicate, predicate significance, variable-valued logical function, logical neural network, cognitive map, cluster analysis, neural network.

REFERENCES

1. Axelrod R., The structure of Decision: Cognitive Maps of Political Elites. Princeton University Press, 1976. — 321 с.
2. Carvahlo J.P., Tome J.A.B., Rule Based Cognitive Maps — A comparison with fuzzy Cognitive Maps//Proceedings of the NAFIPS99, 1999. — 32 с.
3. Lyutikova L.A., Timofeev A.V., Sgurev V.V., Jocov V.I Razvitie i primeneniye mnogoznachnyh logik i setevykh potokov v intellektual'nyh sistemah. // Trudy SPIIRAN, vyp. 2, 2005. S. 114–126.
4. Lyutikova L.A. Modelirovaniye i minimizatsiya baz znaniy v terminah mnogoznachnoy logiki predikatov. Nal'chik. – Preprint, 2006. 33 s.
5. Timofeev A.V., Kosovskaya T.M. Nejrosetevyye metody logicheskogo opisaniya i raspoznavaniya slozhnykh obrazov // Trudy SPIIRAN. 2013. Vyp. 27. С. 144-155.
6. SHibzuhov Z.M. Konstruktivnyye metody obucheniya nejronnykh setej. M.: Nauka, 2006. 159 s.
7. Jürgen Schmidhuber Deep learning in neural networks: An overview Neural Networks Volume 61, January 2015, Pages 85–117
8. Barskij A.B. Logicheskie nejronnye seti. INTUIT; BINOM, 2007. 352 s.
9. Dimitrichenko D. P. Primeneniye peremennoznachnykh logicheskikh funktsiy i nejronnykh setej v sistemah prinyatiya resheniy // Vestnik KRAUNC. Fiz.-mat. nauki. 2016. № 4-1(16). С. 93-100.
10. Dimitrichenko D.P. Ispol'zovaniye nejronnykh setej dlya povysheniya ehffektivnosti peremennoznachnykh logicheskikh funktsiy // Vestnik IrGTU. №10 (105), 2015. S. 12-16.
11. ZHilov R.A., Optimizatsiya kognitivnoy karty dlya zadach prognozirovaniya. // Kibernetika i programmirovaniye. 2015. № 5. S.128-135