

АДАПТИВНОЕ ОБУЧЕНИЕ НЕЧЁТКИХ КОГНИТИВНЫХ КАРТ

С.Н. Чуканов¹

д.т.н., профессор, e-mail: ch_sn@mail.ru

И.С. Чуканов²

магистрант, e-mail: chukanov022@gmail.com

С.В. Лейхтер³

старший преподаватель, e-mail: leykhter@mail.ru

А.В. Калекина⁴

к.э.н., доцент, e-mail: annakav82@mail.ru

И.Е. Чернуха⁵

аспирант, e-mail: ilyachernuha92@gmail.com

¹Институт математики им. С.Л. Соболева СО РАН, Омский филиал, Омск, Россия
²Уральский федеральный университет имени первого Президента России Б.Н. Ельцина,
Екатеринбург, Россия

³Омский государственный университет им. Ф.М. Достоевского, Омск, Россия

⁴Омский институт водного транспорта, Омск, Россия

⁵Омский государственный технический университет, Омск, Россия

Аннотация. Метод нечётких когнитивных карт (FCM) разработан Б. Коско для расширения когнитивных карт, которые широко используются для представления знаний в социальных науках. Предложено несколько алгоритмов для обучения FCM. Основная задача процедуры обучения – найти настройку весов FCM, которая приведёт FCM к требуемому устойчивому состоянию. Это достигается посредством минимизации правильно определённой целевой функции. Установленные алгоритмы в значительной степени зависят от начального приближения матрицы весов, которое предоставляется экспертами. Один из методов обучения FCM основан на оптимизации роя частиц (PSO). PSO используется для определения соответствующих весовых матриц для системы путём минимизации заданной целевой функции.

Ключевые слова: нечёткие когнитивные карты, правило Хебба, оптимизации роя частиц.

Введение

В 1986 г. Б. Коско представил FCM для причинно-следственной обработки и вычислительной обработки оценок причинно-следственных связей, представленных в виде ориентированного графа [1]. Создание FCM требует знаний экспертов о рассматриваемой системе. FCM состоит из концепций $C_i, i = 1, \dots, N$. Каждый узел (концепция) содержит значение $A_i \in [0, 1], i = 1, \dots, N$. Концепции соединены

взвешенными дугами, которые показывают отношения. Связь между двумя концепциями имеет вес W_{ij} . Направление указывает, является ли концепция причиной или следствием. Существует три типа весов:

$$\begin{cases} W_{ij} > 0, & \text{positive causality,} \\ W_{ij} < 0, & \text{negative causality,} \\ W_{ij} = 0, & \text{absence of causality.} \end{cases}$$

На каждом шаге значение концепции A_i находится под влиянием значений других концепций:

$$A_i(k+1) = f \left(A_i(k) + \sum_{\substack{j=1 \\ j \neq i}}^n W_{ji} A_j(k) \right), \quad (1)$$

где W_{ji} – вес дуги, соединяющей концепцию C_j с концепцией C_i ;

$$f(x) = (1 + \exp(-\lambda x))^{-1}. \quad (2)$$

Проектирование FCM опирается на мнения экспертов. Эксперты описывают влияние одной концепции на другую как «негативное», «положительное» или «отсутствие». Метод дефаззификации используется для преобразования лингвистического веса в числовое значение. Преимущество этого подхода в том, что экспертам не нужно напрямую присваивать значения для создания корреляций и эффектов, но им необходимо сравнивать значения между понятиями. Экспертами задаётся начальная матрица весов $W^{initial} = [W_{ij}]; i, j = 1, \dots, N$, с $W_{ii} = 0; i = 1, \dots, N$.

Процедуры обучения представляют собой средства повышения эффективности и надёжности FCM путём обновления матрицы весов. На сегодняшний день существует всего несколько алгоритмов обучения FCM, основанных на опыте обучения нейронных сетей [2]. Такие алгоритмы начинают с начального состояния и начальной матрицы весов $W^{initial}$ FCM и адаптируют веса, чтобы вычислить матрицу весов, которая приводит FCM к желаемому устойчивому состоянию.

1. Алгоритмы обучения

Алгоритм обучения PSO (particle swarm optimization) [3,4] принадлежат к классу алгоритмов роевого интеллекта, вдохновлённых социальной динамикой в организованных колониях (например, пчёл). В алгоритме каждая частица движется в пространстве поиска с адаптивной скоростью и сохраняет в памяти лучшее положение. В глобальной версии PSO наилучшее положение сообщается всем частицам. При этом между частицами происходит обмен информацией о лучшем положении, достигнутом окружающими частицами. i -я частица роя является D -мерным вектором $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})^T \in S \subset \mathbb{R}^D$, а скорость i -й частицы – $V_i = (v_{i1}, v_{i2}, \dots, v_{iD})^T \in S$. Наилучшее положение i -й частицы является точкой $P_i = (p_{i1}, p_{i2}, \dots, p_{iD})^T \in S$. Рой частиц управляется уравнениями:

$$V_i(t+1) = \chi [wV_i(t) + c_1r_1(P_i(t) - X_i(t)) + c_2r_2(P_{g_i}(t) - X_i(t))], \quad (3)$$

$$X_i(t+1) = X_i(t) + V_i(t+1), \quad (4)$$

где $i = 1, \dots, N$; c_1, c_2 – параметры алгоритма; $r_1, r_2 \in [0, 1]$; g_i – индекс частицы, которая достигла наилучшего положения всего роя.

Пусть C_1, \dots, C_N являются концепциями FCM и $C_{out_1}, \dots, C_{out_m}, 1 \leq m \leq N$ – выходными концепциями. Значения выходных концепций должны быть ограниченными экспертами: $A_{out_i}^{\min} \leq A_{out_i} \leq A_{out_i}^{\max}, i = 1, \dots, m$. Основная цель состоит в нахождении весовой матрицы $W = [W_{ij}], i, j = 1, \dots, N$, приводящей FCM к состоянию, при котором выходные концепции лежат в требуемых границах. Рассмотрим целевую функцию

$$F(W) = \sum_{i=1}^m H(A_{out_i}^{\min} - A_{out_i}) |A_{out_i}^{\min} - A_{out_i}| + \sum_{i=1}^m H(A_{out_i} - A_{out_i}^{\max}) |A_{out_i} - A_{out_i}^{\max}|, \quad (5)$$

где

$$H(x) = \begin{cases} 0, & x < 0, \\ 1, & x \geq 0, \end{cases}$$

– функция Хевисайда. FCM с N взаимосвязанными концепциями сталкивается с $N(N-1)$ -мерной задачей минимизации. Процесс PSO для минимизации целевой функции F начинается с этапа инициализации, на котором рой $S = \{X_1, \dots, X_M\}$ случайно формируется и оценивается с использованием F . Алгоритм завершает работу в конце процесса глобальной оптимизации функции F .

Алгоритм обучения Хебба. Цель обучения FCM с использованием адаптивных методов, основанных на правиле Хебба, состоит в получении матрицы весов на основе знаний экспертов и повышении точности ранее определённых весов [5]. Алгоритм дифференциального обучения Хебба (DHL) предполагает, что если концепция причины C_i и концепция следствия C_j одновременно изменяют свои значения активации, то причинный вес W_{ij} должен быть увеличен на постоянный коэффициент; в противном случае причинно-следственная связь не будет изменена в этой итерации. Уравнение (6) отображает правило обновления веса, используемое в этом алгоритме:

$$w_{ij}^{(t+1)} = \begin{cases} w_{ij}^{(t)} + \eta_t [\Delta A_i^{(t)} \Delta A_j^{(t)} - w_{ij}^{(t)}], & \Delta A_i^{(t)} \neq 0, \\ w_{ij}^{(t)}, & \Delta A_i^{(t)} = 0, \end{cases} \quad (6)$$

где η_t – скорость обучения.

2. Пример системы управления

Рассмотрим пример задачи управления процессом для иллюстрации работы предлагаемого алгоритма обучения, в которой имеется 5 объектов с концепциями $C_1 - C_5$.

Пусть дана начальная матрица весов и диапазоны значений весов, заданные экспертами (табл. 1).

Таблица 1. Начальные значения и диапазоны значений весов

W	W^{init}	W^{min}	W^{max}
W_{12}	-0,4	-0,55	-0,25
W_{13}	-0,3	-0,4	-0,2
W_{15}	0,3	0,15	0,45
W_{21}	0,3	0,2	0,4
W_{31}	0,4	0,3	0,5
W_{41}	-0,8	-0,9	-0,7
W_{52}	0,6	0,45	0,75
W_{54}	0,33	0,2	0,4

Таблица 2. Значения концепций в различные моменты времени

k	C_1	C_2	C_3	C_4	C_5
0	0,1	0,45	0,36	0,34	0,01
1	0,1033	0,3865	0,2819	0,2970	0,02
2	0,0970	0,3132	0,2026	0,2534	0,02
3	0,0856	0,2359	0,18	0,2108	0,02
4	0,0815	0,22	0,18	0,1745	0,02
5	0,0903	0,22	0,18	0,17	0,02
6	0,0960	0,22	0,18	0,17	0,02
7	0,0988	0,22	0,18	0,17	0,02
8	0,1001	0,22	0,18	0,17	0,02
9	0,1008	0,22	0,18	0,17	0,02
10	0,1012	0,22	0,18	0,17	0,02
11	0,1013	0,22	0,18	0,17	0,02
12	0,1014	0,22	0,18	0,17	0,02
13	0,1014	0,22	0,18	0,17	0,02
14	0,1015	0,22	0,18	0,17	0,02
15	0,1015	0,22	0,18	0,17	0,02

Значения концептов находятся в пределах, определённых экспертами: $0,05 \leq C_1 \leq 0,2$; $0,22 \leq C_2 \leq 0,9$; $0,18 \leq C_3 \leq 0,72$; $0,17 \leq C_4 \leq 0,68$; $0,005 \leq C_5 \leq 0,02$.

Примем следующие начальные значения концепций: $C_1 = 0,1$; $C_2 = 0,45$; $C_3 = 0,36$; $C_4 = 0,34$; $C_5 = 0,01$.

В результате адаптации весов и значений концепций получим динамический процесс изменения концепций в различные моменты времени, который представлен в табл. 2.

Заключение

FCM успешно используется для проектирования сложных систем. Предложен алгоритм обучения для определения матриц с субоптимальными весами для нечётких когнитивных карт. Метод основан на минимизации целевой функции с использованием алгоритма PSO и обучении, основанном на правиле Хебба.

Благодарности

Работа выполнена по Госзаданию Института математики СО РАН, проект № FWNF-2022-0016.

Литература

1. Kosko B. Fuzzy cognitive maps // International journal of man-machine studies. 1986. Vol. 24, No. 1. P. 65–75.
2. Papageorgiou E., Stylios C.D., Groumpos P.P. Activation hebbian learning rule for fuzzy cognitive maps // IFAC Proceedings Volumes. 2002. Vol. 35, No. 1. P. 319–324.
3. Eberhart R.C., Shi Y., Kennedy J. Swarm Intelligence (Morgan Kaufmann series in evolutionary computation). Morgan Kaufmann Publishers, 2001.
4. Parsopoulos K.E. et al. A first study of fuzzy cognitive maps learning using particle swarm optimization // The 2003 Congress on Evolutionary Computation, 2003. IEEE, 2003. Vol. 2. P. 1440–1447.
5. Dickerson J.A., Kosko B. Virtual worlds as fuzzy cognitive maps // Presence: Teleoperators & Virtual Environments. 1994. Vol. 3, No. 2. P. 173–189.

ADAPTIVE LEARNING OF FUZZY COGNITIVE MAPS**S.N. Chukanov**¹

Dr.Sc. (Techn.), Professor, e-mail: a@a.ru

I.S. Chukanov²

Master's Degree Student, e-mail: chukanov022@gmail.com

S.V. Leykhter³

Assistant Professor, e-mail: leykhter@mail.ru

A.V. Kalekina⁴

PhD (Econ.), Associate Professor, e-mail: annakav82@mail.ru

I.V. Chernuha⁵

Ph.D. Student, e-mail: ilyachernuha92@gmail.com

¹Sobolev Institute of Mathematics, Omsk branch, Omsk, Russia²Ural Federal University named after the first President of Russia B.N. Yeltsin, Ekaterinburg, Russia³Dostoevsky Omsk State University, Omsk, Russia⁴Omsk Institute of Water Transport, Omsk, Russia⁵Omsk State Technical University, Omsk, Russia

Abstract. The Fuzzy Cognitive Map (FCM) method was developed by B. Kosko to extend cognitive maps, which are widely used to represent knowledge in the social sciences. Several algorithms have been proposed for training FCMs. The main objective of the training procedure is to find a setting of FCM weights that will bring the FCM to a desired stable state. This is achieved by minimizing a well-defined objective function. The established algorithms heavily depend on the initial approximation of the weight matrix, which is provided by experts. One of the methods for training FCMs is based on particle swarm optimization (PSO). PSO is used to determine the appropriate weight matrices for the system by minimizing a given objective function.

Keywords: fuzzy cognitive maps, Hebb's rule, particle swarm optimization.

Дата поступления в редакцию: 31.10.2024