

СЕТЬ ART С НЕЧЕТКИМИ ВЕСАМИ СВЯЗЕЙ

Кадомский К.К.

Донецкий национальный университет,
физический факультет, кафедра компьютерных технологий
E-mail: kadomsky@ukr.net

Аннотация

Кадомский К.К. Сеть ART с нечеткими весами связей. Рассмотрена задача структурной классификации нечетких образов. Построение классификатора рассматривается как задача обучения без учителя, которая решается при помощи сети ART с нечеткими весами связей. Обоснована неэффективность существующих модификаций сетей ART при работе с нечеткими входными данными. Рассмотрены основные отличия усовершенствованной модели, которые повышают ее эффективность.

Введение

Задача структурной классификации нечетких образов возникает в нечетких системах ситуационного управления и поддержки принятия решений [1], где входная информация о состоянии объекта управления представлена в нечетком либо лингвистическом виде. В таких системах значения наблюдаемых параметров измеряются неточно, либо оцениваются с некоторой долей уверенности на основе неполной информации. Целью классификации является переход от нечетких данных измерений к абстрактным категориям ситуаций и решений (реакций либо действий системы), удобным для построения отображения множества ситуаций во множество решений. В докладе построение классификатора в процессе работы системы рассматривается как задача кластеризации нечетких образов [2]. Эта задача решается с использованием принципов теории адаптивного резонанса (adaptive resonance theory, ART) [3, 4].

Теория адаптивного резонанса (adaptive resonance theory, ART) является наиболее полной формальной моделью известных нейрофизиологических процессов, связанных с обучением и распознаванием сложных образов человеком, таких как внимание и «схватывание» сложных перцептивных образов. Сеть ART реализует последовательный конкурентный алгоритм кластеризации, известный как конкурентное обучение (competitive learning) [2]. Этот алгоритм эффективен при работе с описаниями ситуации на основе признаков. Однако, существующие модели сети ART (fuzzy ART [4], distributed ART (dART) [5]) работают с аналоговыми (не нечеткими) входными данными. В случае нечетких входных данных используются специальные преобразования входного образа в обычный аналоговый вектор большей размерности [6, 7]. Эффективность классификации при этом снижается.

В докладе предлагается модификация сети ART, которая непосредственно поддерживает нечеткое представление данных и позволяет повысить эффективность и качество классификации нечетких образов.

Общая постановка проблемы

Имеется конечный набор входных образов $I = \{\mathbf{I}^{(i)}\}_{i=1}^k \subset \bar{P}$ из пространства нечетких образов \bar{P} . Каждый образ представлен в виде нечеткого вектора признаков, т.е. упорядоченного набора из n нечетких чисел.

$$\mathbf{I}^{(i)} = \left(X_i^{(i)} \right)_{i=0}^n \quad (1)$$

где $\underline{X}_i^{(t)}$ - нечеткое число вида (2), которое характеризует значение i -го признака;

$$\underline{X}_i^{(t)} = \{x | \mu_{\underline{X}_i^{(t)}}(x)\}_{x \in X_i}, \quad i = \overline{1, n} \quad (2)$$

$X_i \subseteq R$ – его базовое множество;

$\mu_{\underline{X}_i^{(t)}}(x)$ - функция принадлежности.

Входные образы предъявляются по одному. Пусть задана оценка степени сходства нечетких образов $s: \overline{P}^2 \rightarrow [0; 1]$. Необходимо построить разбиение $C = (C_j)_{j=1}^m$ множества входных образов I на основе оценки сходства s , где \underline{C}_j – компактные в смысле оценки s нечеткие подмножества I . Классом либо категорией образов будем называть компактное в смысле оценки s нечеткое подмножество признакового пространства $\underline{C}_j = \{\mathbf{x} | \mu_{C_j}(\mathbf{x})\} \subset X_1 \times \dots \times X_n$. Здесь предполагается, что многомерную функцию принадлежности категории $\mu_{C_j}(\mathbf{x})$ можно представить в виде набора ее одномерных проекций $\mathbf{w}_j \in \overline{P}$, $j = \overline{1, m}$ [8]. Тогда при заданных I и s набор категорий однозначно определяет искомое разбиение C , и задача сводится к нахождению нечетких векторов \mathbf{w}_j .

Классическая сеть fuzzy ART

Сеть fuzzy ART [4] предназначена для решения частного случая поставленной задачи, когда входные образы представлены аналоговыми векторами признаков: $\mathbf{I}^{a(t)} = (x_i^{(t)})_{i=1}^n$, и пространство входных образов совпадает с признаковым пространством: $\overline{P} = X_1 \times X_2 \times \dots \times X_n = [0; 1]^n$. В этом случае категории C_j являются обычными прямоугольными подмножествами \overline{P} . Комплементарное кодирование [4] каждому входному образу $\mathbf{I}^a \in \overline{P}$ ставит в соответствие нормированный вектор $\mathbf{I} \in \overline{P}^2$, такой что $\mathbf{I} = (\mathbf{I}^a, \mathbf{I}^c)$, $\mathbf{I}^c = 1 - \mathbf{I}^a$; каждое прямоугольное подмножество $C_j \subset \overline{P}$ отображается в единственный вектор $\mathbf{w}_j = (\mathbf{w}_j^a, \mathbf{w}_j^c) \in \overline{P}^2$. В качестве оценки степени сходства s в пространстве \overline{P}^2 используется отношение (3).

$$s(\mathbf{I}, \mathbf{w}_j) = |\mathbf{I} \wedge \mathbf{w}_j| / |\mathbf{I}| \quad (3)$$

Нечеткий входной образ (1) перед подачей на вход сети предварительно преобразуется в обычный аналоговый вектор большей размерности $\mathbf{I}^a \in \overline{P}^l$, где каждое нечеткое число \underline{X}_i заменяется набором аналоговых значений функции принадлежности $(\mu_{\underline{X}_i}(x_{i1}), \dots, \mu_{\underline{X}_i}(x_{in}))$, вычисленных с некоторым шагом дискретизации по базовому множеству X_i . В случае лингвистического описания входного образа значение каждой лингвистической переменной заменяется вектором активности ее термов [6, 7].

Критерием отнесения образа \mathbf{I} к категории C_j (критерием резонанса) служит неравенство $s(\mathbf{I}, \mathbf{w}_j) \geq \rho$, где $\rho \in (0; 1)$ – параметр чувствительности сети. Для комплементарно кодированных векторов \mathbf{I} и \mathbf{w}_j это эквивалентно условию $|\mathbf{I}^a - \mathbf{w}_j^a|^+ + |\mathbf{w}_j^c - \mathbf{I}^c|^+ < 1 - \rho$, где $[x]^+ = \max\{x, 0\}$. После первой итерации обучения [4]

имеем: $\mathbf{w}_j^{(1)} = \mathbf{I}^{(0)}$, $|\mathbf{I}^a - \mathbf{I}^{a(0)}| < 1 - \rho$. Т.е. степень близости образов оценивается на основе метрики Хэмминга [1, 8] в пространстве \bar{P}^l . Для нечетких образов оценки расстояния на основе метрик в пространстве \bar{P}^l неэффективны, поскольку а) расстояние между двумя неравными обычными числами не превышает $2/l$ и стремится к 0 при увеличении количества термов либо точек дискретизации; б) пространство нечетких чисел не является метрическим, в частности для него не справедлива аксиома треугольника. Действительно, в данном пространстве присутствует бесконечно размытое нечеткое множество, которое обобщает все возможные нечеткие числа, и потому имеет нулевое расстояние до любого элемента рассматриваемого пространства.

Известно множество модификаций модели ART, которые используют различные способы представления входных образов и различные модификации алгоритма обучения. Наиболее интересны из них ARTMAP [4], реализующая обучение с учителем, distributed ART (dART) [5], реализующая распределенный алгоритм обучения, подобно ИНС прямого распространения, и fusion ART, поддерживающая обучение с подкреплением. Общим недостатком этих моделей в случае нечетких входных данных остается необходимость предварительного преобразования входного образа. В результате а) увеличивается размерность входных образов и объем ресурсов, необходимых для работы сети; б) алгоритм классификации не получает никакой информации о числовых значениях признаков входного образа и поэтому не может выявить количественные отношения между ними; в) в силу приведенных выше замечаний, используемая оценка степени сходства нечетких образов неэффективна.

Сеть ART с нечеткими весами связей

Для преодоления указанных недостатков предлагается использовать нечеткие веса связей $F_1 - F_2$ и нечеткое представление входных образов (1). Числовое значения веса $w_{ij} \in [0;1]$ заменяется нечетким числом $\underline{w}_{ij} \subseteq [0;1]$, которое задается параметрически в виде тройки чисел $(w_{ij}, h_{ij}, c_{ij}) \in [0;1]^3$, где w_{ij} - центр тяжести нечеткого числа [1]; h_{ij} - высота; c_{ij} - степень концентрированности либо разрешающая способность. Каждая категория \underline{c}_j определяется нечетким вектором $\mathbf{w}_j = (w_{ij}, h_{ij}, c_{ij})_{i=1}^n = (v_i^{w_j}, h_i^{w_j}, c_i^{w_j})_{i=1}^n$. Аналогично кодируется и входной нечеткий вектор: $\mathbf{I} = (v_i^I, h_i^I, c_i^I)_{i=1}^n$. В качестве оценки степени сходства s предлагается использовать оценку (4).

$$s\{\mathbf{a}, \mathbf{b}\} = 1 - \frac{1}{\sqrt{n}} \left\| \left((v_i^a - v_i^b) c_i^a c_i^b, (h_i^a \wedge h_i^b), (c_i^a \wedge c_i^b) \right)_{i=1}^n \right\| \quad (4)$$

где $\|\cdot\|$ - взвешенная норма, которая вычисляется по формуле (5);

$$\left\| (v_i, h_i, c_i)_{i=1}^n \right\| \equiv \left(n \sum_{i=1}^n (v_i h_i c_i)^2 / \sum_{i=1}^n (h_i \vee_+ \alpha) \cdot (c_i \vee_+ \alpha)^2 \right)^{1/2} \quad (5)$$

\vee_+ - нечеткая дизъюнкция: $a \vee_+ b = a + b - ab$.

Обучение сети производится по формулам (6)-(8).

$$w_{ij}^{new} = (1 - \beta_{ij}^w) \cdot w_{ij} + \beta_{ij}^w \cdot v_i^I, \quad \beta_{ij}^w = \beta \cdot (h_i^I c_i^I \wedge h_{ij} c_{ij}) \quad (6)$$

$$h_{ij}^{new} = (1 - \beta_{ij}^h) \cdot h_{ij} + \beta_{ij}^h \cdot (h_i^t \vee h_{ij}), \quad \beta_{ij}^h = \beta \cdot h_i^t c_i^t \cdot (1 - |w_{ij} - v_i^t| c_{ij} c_i^t) \quad (7)$$

$$c_{ij}^{new} = (1 - \beta_{ij}^c) \cdot c_{ij} + \beta_{ij}^c \cdot (c_i^t \wedge (1 - |w_{ij} - v_i^t| c_{ij} c_i^t)), \quad \beta_{ij}^c = \beta \cdot h_i^t c_i^t \quad (8)$$

Скорость обучения, в отличие от существующих моделей ART, является функцией текущего входного образа и состояния сети.

Результаты

На рис. 1 показан процесс обучения сети ART с нечеткими весами связей. Сеть имеет три входа ($n = 3$). Использовались следующие значения параметров: $\alpha = 0.1$, $\beta = 0.5$, $\rho = 0.8$. Обучающая выборка состоит из четырех нечетких образов: $\mathbf{I}^{(0)}$, $\mathbf{I}^{(1)}$, $\mathbf{I}^{(2)}$, $\mathbf{I}^{(3)}$ (на рис. 1 - слева). Все входные образы сетью отнесены к категории C_1 , которая определяется нечетким вектором весов \mathbf{w}_1 и обобщает все отнесенные к ней образы.

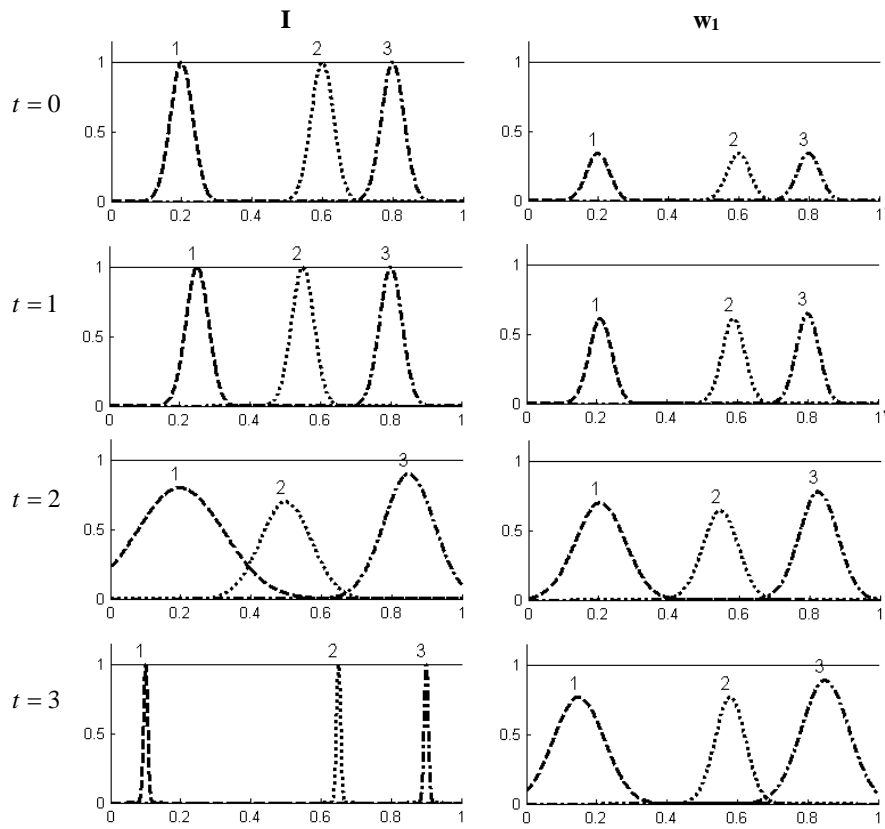


Рис. 1. Иллюстрация процесса обучения обобщенной сети ART

На рис. 2 приведен результат обучения сети fuzzy ART на той же обучающей выборке. Входные образы также отнесены к одной категории C_1 , однако сформированная сетью функция принадлежности категории, сильно искажена. В результате на очередной итерации обучения ($t = 4$) первый входной образ ($\mathbf{I}^{(1)}$) не был отнесен к категории C_1 .




Рис. 2. Результат обучения сети fuzzy ART

Выводы

Теория адаптивного резонанса (adaptive resonance theory, ART) используется для моделирования известных нейрофизиологических процессов, связанных с обучением и распознаванием сложных образов человеком. Сеть ART реализует кластеризацию множества образов, которые представлены обычными векторами признаков. Для нечетких либо лингвистических входных данных существующие модели неэффективны. Предложена усовершенствованная модель сети ART, которая поддерживает нечеткие веса связей и непосредственно работает с нечетким представлением входных образов. Предложенная модель позволяет повысить эффективность применения принципов ART в задаче структуризации базы знаний нечеткой системы управления по сравнению с существующими исследованиями [6, 7]. Модель апробирована в составе автоматической системы управления роботом Lego® Mindstorms® NXT 2.0.

Литература

1. Мелихов А. Н. Ситуационные советующие системы с нечеткой логикой [Текст] / А. Н. Мелихов, Л. С. Берштейн, С. Я. Коровин. – М. : Наука. Физматлит, 1990. – 272 с. : ил. – ISBN 5-02-014144-5.
2. Romesburg C. Cluster analysis for researchers [Текст] / Н. Charles Romesburg. – New York : Lulu Press, 2004. – 344 p. – ISBN 1-411-60617-5.
3. Carpenter G. A. Adaptive resonance theory [Текст] : The handbook of brain theory and neural networks / Gail A. Carpenter and Stephen Grossberg ; in M. A. Arbib (ed.). – 2nd edition. – Cambridge, MA : MIT Press, 2003. – P. 87-90. – ISBN 0-262-51102-9.
4. Carpenter G. A. Fuzzy ART: fast stable learning and categorization of analog patterns by an adaptive resonance system / G. A. Carpenter, S. Grossberg, D. B. Rosen // Neural Networks. – 1991. - No. 4. – P. 759-771. – ISSN 0893-6080.
5. Carpenter G. A. Distributed learning, recognition, and prediction by ART and ARTMAP neural networks / G. A. Carpenter // Neural networks. – 1997. - Vol. 10. No 8. - P. 1473-1494. – ISSN 0893-6080.
6. Нечаев Ю. И. Анализ сложных ситуаций на основе принципа адаптивного резонанса в высокопроизводительных системах обучения и принятия решений / Ю. И. Нечаев, О. Н. Петров // Телематика'2005 : XII Всероссийская научно-методическая конференция : материалы. – СПб. : СПбГУ ИТМО, 2005. - Т. 1. – С. 301-302. – ISBN 5-318-00358-3.
7. Нечаев Ю. И. Распознавание динамических ситуаций с помощью нейронных сетей / Ю. И. Нечаев, И. А. Кирюхин // Нейрокомпьютеры: разработка, применение. – 2007. - № 6. – С. 34-42. – ISSN 1999-8554.

8. Каргин А. А. Введение в интеллектуальные машины. Книга 1. Интеллектуальные регуляторы [Текст] / А. А. Каргин. – Донецк: Норд-Пресс, ДонНУ, 2010. – 526 с. – ISBN 978-966-380-451-4