

## ОБОБЩЕННАЯ МЕТОДОЛОГИЯ ОПРЕДЕЛЕНИЯ ЧИСЛА КЛАСТЕРОВ В НЕЧЕТКОМ $c$ -РАЗБИЕНИИ ПРИ КЛАССИФИКАЦИИ МОДЕЛЕЙ

К. М. Садовская (Минск, Беларусь)

Как отмечается в работе [6], «в настоящее время особую значимость начинают приобретать вопросы оценивания и анализа качества моделей, классификации, упорядочения и обоснованного выбора состава и структур моделей и полимодельных комплексов, управления их качеством». Классификация моделей некоторого процесса или объекта является необходимым этапом исследования, определяющим выбор модели, наиболее адекватной условиям поставленной задачи. Если  $X = \{x_1, \dots, x_n\}$  – множество  $n$  моделей, описывающих некоторый процесс или объект  $\chi$ , и каждая модель  $x_i \in X, i = 1, \dots, n$  характеризуется  $m$  признаками, то задача классификации моделей состоит в разбиении множества  $X$ , данные о котором представлены в виде матрицы

$$X_{n \times m} = \begin{pmatrix} x_1^1 & x_1^2 & \dots & x_1^m \\ x_2^1 & x_2^2 & \dots & x_2^m \\ \dots & \dots & \dots & \dots \\ x_n^1 & x_n^2 & \dots & x_n^m \end{pmatrix}, \quad (1)$$

именуемой матрицей «объект–свойство» [4], где  $x_i^t$  представляет собой значение  $t$ -го признака у  $i$ -го объекта множества  $X$ , на заданное или нет число  $c$  классов.

В последние годы значительно выросло количество публикаций, посвященных различным аспектам нечеткого подхода к решению задач классификации. Это обусловлено тем, что, как отмечал профессор Л. А. Заде, «большинство реальных кластеров размыты по своей природе в том смысле, что переход от принадлежности к непринадлежности для этих классов скорее постепенен, чем скачкообразен» [3]. Наибольшее распространение среди нечетких методов распознавания образов получили нечеткие методы автоматической классификации, подробно рассматриваемые в работе [1], которые объединяются в эвристическое, оптимизационное и иерархическое направления.

Оптимизационные методы нашли наибольшее распространение при решении задач нечеткой кластеризации. При их использовании целью решения задачи является разбиение исследуемой совокупности объектов на семейство  $c$  нечетких множеств, называемых нечеткими кластерами. Нечеткие множества  $A^l, l = 1, \dots, c$ , определенные на множестве классифицируемых объектов  $X = \{x_1, \dots, x_n\}$ , с соответствующими функциями принадлежности  $\mu_{li}, l = 1, \dots, c, i = 1, \dots, n$ , образуют нечеткое  $c$ -разбиение  $P = \{A^1, \dots, A^c\}$  на заданное число  $c$  классов, если для каждого объекта  $x_i \in X$  выполняется условие  $\sum_{l=1}^c \mu_{li} = 1$ , так что задача нечеткой кластеризации заключается в нахождении экстремума некоторого функционала  $Q(P)$  на множестве  $\Pi$  всех нечетких  $c$ -разбиений  $P$  исследуемой совокупности объектов  $X = \{x_1, \dots, x_n\}$ , что описывается формулой  $Q(P) \rightarrow \underset{P \in \Pi}{extr}$ . Решением задачи классификации будет нечеткое разбиение  $P^*$  на заданное число классов  $c$ , соответствующее, в зависимости от вида целевой функции, наименьшему либо, напротив, наибольшему значению  $Q(P)$ . Поскольку в качестве входного параметра во всех существующих оптимизационных нечетких методах автоматической классификации должно задаваться число нечетких кластеров  $c$ , которое может быть и неизвестным исследователю, возникает проблема определения наиболее

адекватного числа  $c$  классов в искомом нечетком  $c$ -разбиении  $P^*$ , для решения которой, в свою очередь, различными исследователями был предложен ряд показателей, вычисление которых для различного числа нечетких кластеров помогает определить наиболее «приемлемое» значение  $c$ , т. е. наиболее «естественное» число нечетких кластеров, на которое «расслаивается» исследуемая совокупность объектов. Для всех показателей числа классов в нечетком  $c$ -разбиении решение задачи определения оптимального числа классов в искомом нечетком разбиении определяется общим выражением

$$\text{extr}_c(V_c(P)), c = 2, \dots, n-1, \quad (2)$$

где символом  $V_c(P)$  обозначен какой-либо показатель.

В работе [2] было предложено объединить алгоритм, вычисляющий нечеткое  $c$ -разбиение, оптимальное в смысле используемого функционала  $Q(P)$ , и процедуру вычисления соответствующего этому алгоритму показателя оптимальности числа нечетких классов в нечетком разбиении, в рамках одной процедуры. Процедура, объединяющая  $FCM$ -алгоритм, отыскивающий нечеткое  $c$ -разбиение, оптимальное в смысле функционала Дж. Данна и Дж. Беждека [7]

$$Q(P) = \sum_{l=1}^c \sum_{i=1}^n \mu_{li}^\gamma \|x_i - \tau^l\|^2, \quad (3)$$

и процедуру вычисления некоторого показателя оптимальности числа классов в нечетком  $c$ -разбиении, ряд которых рассмотрен в работе [2], для различных значений числа классов  $c$ , получила название  $FCM - CV$ -алгоритма. Параметрами  $FCM - CV$ -алгоритма являются показатель нечеткости классификации  $\gamma$ , используемый в  $FCM$ -алгоритме, а также значения  $c_*$  и  $c^*$ , где  $c_* \geq 2$  – наименьшее и  $c^* \leq n-1$  – наибольшее из возможного числа классов в искомом разбиении, так что сущность  $FCM - CV$ -алгоритма заключается в построении множества нечетких  $c$ -разбиений для различных значений  $c \in [c_*, c^*]$  и вычислении показателя оптимальности числа классов  $V_c(P)$  для каждого  $P$  с последующим выбором некоторого нечеткого разбиения  $P^*$ , оптимального в смысле используемого показателя  $V_c(P)$ . Когда исследователь не обладает информацией, позволяющей определить значения  $c_*$  и  $c^*$ , полагается  $c_* := 2$  и  $c^* := n-1$ .

Вместе с тем при большом количестве  $n$  объектов в исследуемой совокупности  $X = \{x_1, \dots, x_n\}$  число вычислений резко возрастает, поэтому возникает необходимость определения интервала  $[c_*, c^*]$  значений наиболее возможного числа классов в искомом  $P^*$ , для чего в работе [5] была предложена методика применения аппарата треугольных нечетких чисел. Сущность этой методики заключается в построении исследователем треугольного нечеткого числа  $V = (\hat{c}, 2, n-1)$  с функцией представления формы  $\mu_V(l)$  на основании задаваемого исследователем наиболее возможного  $\hat{c}$  числа нечетких кластеров, представляющего собой модальное значение нечеткого числа  $V$ , и построением интервала достоверности  $[c_*, c^*]$  как множества натуральных чисел, таких, что  $c_* \geq c'$  и  $c^* \leq c''$ , где интервал  $[c', c'']$  представляет собой  $\alpha$ -срез нечеткого числа  $V$ .

Таким образом, когда число классов в искомом нечетком  $c$ -разбиении  $P^*$  неизвестно и может быть определено лишь приблизительно, к примеру, на основании разведочного анализа данных [4], процесс классификации условно делится на два этапа: построение интервала достоверности  $[c_*, c^*]$  числа классов в искомом  $P^*$  и обработка данных  $FCM - CV$ -алгоритмом в построенном интервале достоверности.

Вместе с тем *FCM*-алгоритм, отыскивающий минимум функционала (2), представляет собой параметрическое семейство по  $\gamma$  при фиксированном числе кластеров  $c$  [4], [7], так что при увеличении значения  $\gamma$  возрастает неопределенность классификации, затрудняющая интерпретацию результатов, что выражается соотношением

$$\gamma \rightarrow \infty \Rightarrow \mu_{li} \rightarrow \frac{1}{c}, \forall l=1, \dots, c, \forall i=1, \dots, n, \quad (4)$$

что, в свою очередь, влияет на поведение показателей  $V_c(P)$ , поэтому при больших значениях  $\gamma$  иногда оказывается невозможным определить локальный экстремум показателя  $V_c(P)$  в интервале достоверности  $[c_*, c^*]$ . С этой целью вышеизложенная методология классификации может быть обобщена, для чего в *FCM* – *CV*-алгоритме вместо величины  $V_c(P)$  следует вычислять величину  $V_c(P) \cdot \mu_\nu(l)$ , где значения функции представления формы  $\mu_\nu(l)$  определяются для всех  $c \in [c_*, c^*]$ .

В качестве примера для проведения вычислительного эксперимента были выбраны данные, использованные К.Г. Луни в качестве тестовых в работе [8]. Пятнадцать объектов исследуемой совокупности, структура которой изображена на рис. 1, представляют собой точки в двумерном признаковом пространстве.




Рис. 1. Исходные данные для вычислительного эксперимента


Эксперименты проводились с использованием в качестве показателя  $V_c(P)$  энтропии нечеткого  $c$ -разбиения  $V_{pe}(P)$ , определяемой выражением [7]

$$V_{pe}(P) = -\frac{1}{n} \sum_{l=1}^c \sum_{i=1}^n |\mu_{li} \cdot \ln \mu_{li}|, \quad (5)$$

где  $n$  – число объектов исследуемой совокупности. При использовании  $V_{pe}(P)$  условие (2) принимает вид


$$\min_c (V_{pe}(P)), c = 2, \dots, n-1. \quad (6)$$

Результаты эксперимента, проведенного для  $\hat{c} = 6, \alpha = 0,7$ , представлены ниже. На рис. 2 изображено треугольное нечеткое число, соответствующее  $\hat{c} = 6$ , а также интервал достоверности  $[c_* = 5, c^* = 8]$ , соответствующий заданному значению порога  $\alpha = 0,7$ .



**Рис. 2.** Функция представления формы треугольного нечеткого числа для  $\hat{c} = 6$  и интервал достоверности  $[c_* = 5, c^* = 8]$  при значении порога  $\alpha = 0,7$

На рис. 3 приведен график поведения величины  $V_{pe}(P) \cdot \mu_V(l)$  в интервале  $[c_* = 5, c^* = 8]$  при значении показателя нечеткости классификации  $\gamma = 2$ .



**Рис. 3.** Значения величины  $V_{pe}(P) \cdot \mu_V(l)$  нечеткого  $c$ -разбиения при  $\gamma = 2$

Результаты вычислительных экспериментов позволяют сделать вывод о высокой эффективности  $FCM - CV$ -алгоритма в сочетании с предлагаемым подходом к построению интервала достоверности  $[c_*, c^*]$ , основанного на применении нечетких чисел, благодаря значительному уменьшению вычислений при поиске нечеткого  $c$ -разбиения  $P^*$  на оптимальное число классов в полностью автоматическом режиме, а также возможности учета степени уверенности исследователя в принимаемом им решении о задаваемом в качестве параметра числе классов  $c$ , выражаемой в задаваемом значении порога  $\alpha$ , что является приемлемым с психологической точки зрения.

Поведение величины  $V_{pe}(P) \cdot \mu_V(l)$  наглядно демонстрирует, что, как и при использовании энтропии  $V_{pe}(P)$ , исследуемая совокупность «расслаивается» на восемь

нечетких кластеров. Матрица соответствующего нечеткого  $c$ -разбиения  $P^*$  представлена в таблице.

Таблица 1

**Матрица нечеткого  $c$ -разбиения исследуемой совокупности на восемь классов**

Номер объекта	Номер класса							
	1	2	3	4	5	6	7	8
1	0,0054	0,7863	0,0072	0,0122	0,0046	0,1751	0,0048	0,0043
2	0,0061	0,0019	0,0026	0,0020	0,0059	0,0021	0,0247	0,9547
3	0,0104	0,0024	0,9421	0,0373	0,0009	0,0037	0,0014	0,0018
4	0,0042	0,8609	0,0050	0,0078	0,0041	0,1101	0,0043	0,0037
5	0,0046	0,0061	0,0033	0,0033	0,9200	0,0055	0,0421	0,0150
6	0,0081	0,1681	0,0106	0,0182	0,0052	0,7778	0,0062	0,0058
7	0,0020	0,0015	0,0012	0,0011	0,0184	0,0015	0,9572	0,0172
8	0,4878	0,0366	0,2030	0,1105	0,0206	0,0525	0,0357	0,0532
9	0,0409	0,0204	0,0202	0,0175	0,0667	0,0220	0,3632	0,4492
10	0,0051	0,1200	0,0077	0,0153	0,0031	0,8419	0,0035	0,0034
11	0,0234	0,0119	0,0123	0,0105	0,0775	0,0123	0,4402	0,4119
12	0,0005	0,0004	0,0023	0,9959	0,0001	0,0006	0,0001	0,0001
13	0,0122	0,0113	0,0079	0,0075	0,6614	0,0107	0,2290	0,0599
14	0,9658	0,0022	0,0123	0,0056	0,0018	0,0028	0,0034	0,0061
15	0,4149	0,0321	0,2865	0,1097	0,0233	0,0413	0,0366	0,0555

Вычисление величины  $V_{pe}(P) \cdot \mu_V(l)$  вместо энтропии  $V_{pe}(P)$  предпочтительно при достаточно больших значениях  $\gamma$  и, кроме того, позволяет учитывать «степень достоверности» числа классов  $c \in [c^*, c^*]$ .

### Литература

1. **Вятченин Д. А.** Нечеткие методы автоматической классификации. – Минск.: УП Технопринт, 2004. – 219 с.
2. **Вятченин Д. А., Садовская К. М.** Процедура поиска нечеткого разбиения множества объектов на оптимальное число классов//Сборник научных статей Военной академии Республики Беларусь. – 2004. – № 7. – С. 85–88.
3. **Заде Л. А.** Размытые множества и их применение в распознавании образов и кластер-анализе//Классификация и кластер/Под ред. Дж. Вэн Райзина; пер с англ.; под ред. Ю.И.Журавлева. – М.: Мир, 1980. – С. 208–247.
4. Прикладная статистика: Классификация и снижение размерности: Справ. изд./С. А. Айвазян, В. М. Бухштабер, И. С. Енюков, Л. Д. Мешалкин; Под ред. С.А. Айвазяна. – М.: Финансы и статистика, 1989. – 607 с.
5. **Садовская К. М.** Применение нечетких чисел для построения интервала достоверности числа кластеров в нечетком разбиении//Вестник Военной академии Республики Беларусь. – 2005. – № 3. – С. 27–31.
6. **Соколов Б. В., Юсупов Р. М.** Концептуальные и методические основы квалиметрии моделей и полимодельных комплексов//Труды СПИИРАН. Вып. № 2 – СПб: СПИИРАН, 2004.
7. **Bezdek J. C.** Pattern Recognition with Fuzzy Objective Function Algorithms. – New York: Plenum Press, 1981. – 230 p.
8. **Looney C. G.** Interactive clustering and merging with a new fuzzy expected value // Pattern Recognition. – 2002. – Vol. 35. – P. 2413–2423.