



УДК 004.021

ОБ ОДНОМ МЕТОДЕ МНОГОФАКТОРНОЙ КЛАСТЕРИЗАЦИИ ОБЪЕКТОВ

Букачев Д.С.

*ФГБОУ ВПО Смоленский государственный университет, Смоленск, Россия
(21400, г. Смоленск, ул. Пржевальского, 4), e-mail: dsbuka@yandex.ru*

Настоящая статья посвящена построению конструктивного алгоритма многофакторного разбиения множества объектов на группы в соответствии со схемой иерархической классификации. В результате функционирования алгоритма определяется количество кластеров и групповая принадлежность каждого элемента.

Ключевые слова: кластеризация, метрика, диаметр кластера.

ABOUT ONE MULTI-FACTOR CLUSTERING OBJECTS METHOD

Bukachev D.S.

*Federal State Educational Institution of Higher Professional Education Smolensk State University,
Smolensk, Russia (21400, Smolensk, street Przewalski, 4),
e-mail: dsbuka@yandex.ru*

This article is dedicated to building a constructive algorithm for multivariate partitioning a set of objects into groups in accordance with the hierarchical classification scheme. As a result of the operation of the algorithm determines the number of clusters and group affiliation of each element.

Keywords: clustering, metric, diameter of the cluster.

Спектр применений кластерного анализа весьма широк [1-3]: его используют в археологии, медицине, психологии, химии, биологии, государственном управлении, филологии, антропологии, маркетинге, социологии и других дисциплинах. В данной статье предлагается конструктивный алгоритм многофакторного разбиения множества объектов на группы в соответствии со схемой иерархической классификации.

При реализации алгоритма используются следующие входные данные:

- количество объектов n , их характеристики $X_i \in \Omega_i$ ($i = \overline{1, m}$), упорядоченные по убыванию значимости;
- метрики ρ_i , определенные на множествах Ω_i ;
- допустимые метрические диаметры $\rho_{i\max}$ кластера по каждой из метрик ρ_i .

В результате функционирования алгоритма по входным данным определяется набор выходных значений следующих параметров:

- N_g – количество кластеров;

- g_k – номер кластера объекта с номером k , $k = \overline{1, n}$.

Описание алгоритма

Шаг 1. Будем считать, что изначально объекты принадлежат одной группе. Устанавливаем начальные значения выходных параметров: $N_g = 1$, $g_k = 1$ ($k = \overline{1, n}$).

Шаг 2. Последовательное разбиение объектов по каждой из характеристик. Введем в рассмотрение массив меток L длиной n .

Для всех $n_\rho = \overline{1, m}$:

Для всех $n_g = \overline{1, N_g}$:

Шаг 2.1. Первичная кластеризация группы n_g (проверка парной совместимости).

1. Формируем массив M номеров объектов, принадлежащих группе с номером n_g .
2. Если количество K элементов массива M больше 1, переходим к пункту 2.1.3, в противном случае рассматриваем следующую группу.
3. Присваиваем L_j ($j = \overline{1, n}$) начальное значение 0. Переменной r (количество образованных подкластеров в процессе разбиения) также присваиваем начальное значение 0.

4. Для всех $i_1, i_2 = \overline{1, K}$, $i_2 > i_1$:

Если $\rho_{n_\rho}(M_{i_1}, M_{i_2}) \leq \rho_{n_\rho, \max}$:

1. $L_{\min} = \text{Min}(L_{M_{i_1}}, L_{M_{i_2}})$; $L_{\max} = \text{Max}(L_{M_{i_1}}, L_{M_{i_2}})$;

2. если $L_{\max} = 0$, то $r = r + 1$; $l = r$;

3. если $((L_{\min} = 0) \wedge (L_{\max} > 0)) \vee ((L_{\min} > 0) \wedge (L_{\min} = L_{\max}))$, то $l = L_{\max}$;

4. если $(L_{\min} > 0) \wedge (L_{\min} \neq L_{\max})$, то

а. для всех $j = \overline{1, K}$:

если $L_{M_j} \geq L_{\max}$, то

если $L_{M_j} = L_{\max}$, то $L_{M_j} = L_{\min}$,

иначе $L_{M_j} = L_{M_j} - 1$;

б. $r = r - 1$; $l = L_{\min}$;

5. $L_{M_{i_1}} = l$; $L_{M_{i_2}} = l$.

5. Для всех $j = \overline{1, K}$:

если $L_{M_j} = 0$: $r = r + 1$; $L_{M_j} = r$.

Шаг 2.2. Вторичная кластеризация (обеспечение групповой совместимости).

Для всех $i = \overline{1, r}$:

1. Формируем массив M номеров объектов группы с номером n_g , для которых соответствующее значение метки L равно i (то есть группируем элементы, относящиеся к подклассу с номером i , образованному при первичной кластеризации).
2. Если количество K элементов массива M больше 1, переходим к пункту 2.2.3, в противном случае рассматриваем следующий подкласс.

3. Логической переменной $TrueCluster$ присваиваем значение ($K < 3$); переменным nL и nR присваиваем 1 и 2 соответственно.
4. Пока не $TrueCluster$:
 1. $R_{\max} = 0$;
 2. Для всех $i_1, i_2 = \overline{1, K}, i_2 > i_1$:
 Если $L_{M_{i_1}} = L_{M_{i_2}}$:
 $\rho = \rho_{n_p}(M_{i_1}, M_{i_2})$;
 если $R_{\max} < \rho$, то $R_{\max} = \rho, nL = i_1, nR = i_2$;
 3. Если $R_{\max} = 0$, то
 $TrueCluster = "истина"$;
 иначе
 $TrueCluster = (\rho_{n_p}(M_{nL}, M_{nR}) \leq \rho_{n_p, \max})$;
 4. Если не $TrueCluster$:
 - а) $r = r + 1; L_{M_{nR}} = r$;
 - б) для всех $j = \overline{1, K}, j \neq nL, j \neq nR, L_{M_j} = i$:
 $\rho_L = \rho_{n_p}(M_j, M_{nL})$;
 $\rho_R = \rho_{n_p}(M_j, M_{nR})$;
 если $\rho_R \leq \rho_{\max}$:
 если $\rho_L \leq \rho_{\max}$:
 если $\rho_R < \rho_L$, то $L_{M_j} = r$;
 иначе $L_{M_j} = r$;

Шаг 2.3. Если количество подклассов r , полученных при разбиении группы с номером n_g , больше 1, переопределяем характеристики N_g и g_k :

1. $N_g = N_g + r - 1$
2. Для всех $k = \overline{1, n}$:
 если $g_k > n_g$, то $g_k = g_k + r - 1$;
 если $g_k = n_g$, то $g_k = g_k + L_k - 1$.

Таким образом, получили значения заявленных выходных параметров: N_g (количество кластеров) и g_k (индекс принадлежности объекта), $1 \leq k \leq n$.

Предложенный конструктивный метод обеспечивает многофакторное разбиение множества объектов на группы в соответствии со схемой иерархической классификации.

Список литературы

1. Воронцов К.В. Алгоритмы кластеризации и многомерного шкалирования. Курс лекций. МГУ, 2007.
2. Котов А., Красильников Н. Кластеризация данных, 2006.

3. Jain A., Murty M., Flynn P. Data Clustering: A Review. // ACM Computing Surveys. 1999. Vol. 31, no. 3.

References

1. Voroncov K.V. Algoritmy klasterizacii i mnogomernogo shkalirovanija. Kurs lekcij. MSU, 2007.
 2. Kotov A., Krasil'nikov N. Klasterizacija dannyh, 2006.
 3. Jain A., Murty M., Flynn P. Data Clustering: A Review. // ACM Computing Surveys. 1999. Vol. 31, no. 3.
-