

ОБ ОДНОЙ ЗАДАЧЕ КЛАССИФИКАЦИИ

А.В.Козина

Классификация многомерных объектов - одна из основных задач обработки данных, например социологических. Так, задачей кластерного (классификационного) анализа является разбиение множества объектов, описываемых набором признаков, на K классов (кластеров) таким образом, чтобы "похожие" объекты принадлежали одному и тому же классу, а "непохожие" - разным. Критерием оптимальности может быть функционал, выражающий качество разбиения. Задавая вид этого функционала, который диктуется содержательным анализом, получаем различные задачи классификации (кластеризации) [1, 2].

§ I. Постановка задачи

Пусть заданы признаки T_1, \dots, T_m и P_j ($j = 1, \dots, m$) - множество значений j -го признака. Обозначим через P^m множество всевозможных наборов $a = (a_1, \dots, a_m)$ длины m , j -е компоненты которых принадлежат P_j , $j = 1, \dots, m$, мощность этого множества будет $|P^m| = \prod_{j=1}^m |P_j|$. Далее, пусть X - произвольное множество мощности n наборов из P^m , не обязательно различных, элементы которого пронумерованы в некотором порядке, т.е.

$$X = \{x^i = (x_1^i, \dots, x_m^i) | (x_1^i, \dots, x_m^i) \in P^m, i = 1, \dots, n\}.$$

В дальнейшем элементы множества X будем называть объектами. Тогда для объекта $x^i = (x_1^i, \dots, x_m^i)$ компоненту x_j^i набора назовем значением признака T_j на объекте x^i . По определению, будем считать, что объекты x^s и x^t различаются на множестве X , если $s \neq t$. Разбиением множества X назовем такое семейство его непустых подмножеств $X_s \subseteq X$, что $X = \bigcup_{s=1}^k X_s$, $X_s \cap X_t = \emptyset$ для $s \neq t$, и обозначим это разбиение через $\mathcal{A}(X) = \{X_1, \dots, X_k\}$, подмножества X_s назовем классами. Задача заключается в том, чтобы найти оптимальное в смысле некоторого критерия разбиение множества X объектов на классы. Введем этот критерий.

Определим меру различия на множестве P^m . Для наборов

$$a = (a_1, \dots, a_m), b = (b_1, \dots, b_m) \in P^m$$

имеем

$$\rho(a, b) = \frac{1}{m} \sum_{j=1}^m \varepsilon_j(a_j, b_j),$$

где ε_j - функционал, определенный на парах элементов множества P_j и обладающий свойствами: $\varepsilon_j(a_j, b_j) \geq 0$, $\varepsilon_j(a_j, b_j) = \varepsilon_j(b_j, a_j)$ и $\varepsilon_j(a_j, a_j) = 0$. В зависимости от выбранных ε_j функционал $\rho(a, b)$ может быть метрикой (расстоянием), что превращает P^m в метрическое пространство. Конкретный вид функционала ε_j , вообще говоря, определяется содержательной постановкой задачи и в данной работе не рассматривается. Если $x^i = (x_1^i, \dots, x_m^i) \in X$ и $a = (a_1, \dots, a_m) \in P^m$, то, по определению, имеем $\rho(x^i, a) = \frac{1}{m} \sum_{j=1}^m \varepsilon_j(x_j^i, a_j)$.

Центром произвольного подмножества X_0 множества X называется набор $c \in P^m$, для которого

$$\sum_{x^i \in X_0} \rho(x^i, c) = m \cdot n \sum_{a \in P^m} \rho(x^i, a). \quad /1/$$

Величину

$$\Phi(X_0) = \frac{1}{|X_0|} \sum_{x^i \in X_0} \rho(x^i, c) \quad /2/$$

назовем степень неоднородности множества X_0 . Степень неоднородности разбиения $\mathcal{A}(X) = \{X_1, \dots, X_K\}$ называется функционал

$$\Phi(\mathcal{A}) = \sum_{s=1}^K \frac{|X_s|}{n} \Phi(X_s). \quad /3/$$

Из /1/, /2/ и /3/ следует, что

$$\Phi(\mathcal{A}) = \frac{1}{n} \sum_{s=1}^K \sum_{x^i \in X_s} (\rho(x^i, c^s)),$$

где c^s - центр множества X_s , $s = 1, \dots, K$. Обозначив через $\mathcal{A}(X)$ множество всевозможных разбиений множества X , назовем разбиение $\mathcal{A}(X) \in \mathcal{A}'(X) \subseteq \mathcal{A}(X)$ оптимальным на множестве $\mathcal{A}'(X)$, если

$$\Phi(\mathcal{A}) = \min_{\mathcal{A}' \in \mathcal{A}'(X)} \Phi(\mathcal{A}').$$

Ставится задача: построить разбиение, оптимальное на множестве $\mathcal{A}_K(X)$ всех разбиений на K классов.

§ 2. Некоторые свойства задачи.

Пусть для фиксированного натурального K задана последовательность наборов $C = \{c^1, \dots, c^K\}$, $c^s \in P^m$, $s = 1, \dots, K$. Тогда через $\mathcal{A}(X, C)$ обозначим множество всех таких разбиений $\mathcal{A}(X) = \{X_1, \dots, X_K\}$, что для каждого $s = 1, \dots, K$ набор c^s является центром класса X_s . Будем говорить, что разбиение $\mathcal{A}(X) = \{X_1, \dots, X_K\}$ порождено после-

довательностью наборов C , если для каждого $s = 1, \dots, K$ и каждого объекта $x^i \in X_s$ выполняется неравенство $\rho(x^i, c^s) \leq \rho(x^i, c^t)$ для всех $t = 1, \dots, K$.

Нетрудно убедиться в том, что для любого разбиения $\mathcal{A}_1(X) = \{X_1^1, \dots, X_K^1\} \in \mathcal{O}(X, C)$ и любого разбиения $\mathcal{A}_2(X) = \{X_1^2, \dots, X_K^2\}$, порожденного последовательностью наборов C , справедливо неравенство $\Phi(\mathcal{A}_2) \leq \Phi(\mathcal{A}_1)$, причем если $\mathcal{A}_2 \notin \mathcal{O}(X, C)$, то $\Phi(\mathcal{A}_2) < \Phi(\mathcal{A}_1)$.

Действительно, для произвольной фиксированной последовательности наборов $C = \{c^1, \dots, c^K\}$ положим

$$\Psi(\mathcal{A}) = \frac{1}{n} \sum_{s=1}^K \sum_{x^i \in X_s} \rho(x^i, c^s),$$

где $\mathcal{A}(X) = \{X_1, \dots, X_K\}$. Тогда для разбиения $\mathcal{A}(X) \in \mathcal{O}(X, C)$ выполняется равенство $\Psi(\mathcal{A}) = \Phi(\mathcal{A})$. Если же $\mathcal{A}(X) \notin \mathcal{O}(X, C)$, то найдется такое целое t , $1 \leq t \leq K$, что c^t не является центром класса X_t . Поэтому

$$\sum_{x^i \in X_t} \rho(x^i, \hat{c}^t) < \sum_{x^i \in X_t} \rho(x^i, c^t),$$

$$\sum_{x^i \in X_s} \rho(x^i, \hat{c}^s) \leq \sum_{x^i \in X_s} \rho(x^i, c^s) \quad \text{для всех } s \neq t,$$

где \hat{c}^s - центр класса X_s , $s = 1, \dots, K$.

Следовательно,

$$\Phi(\mathcal{A}) = \frac{1}{n} \sum_{s=1}^K \sum_{x^i \in X_s} \rho(x^i, \hat{c}^s) < \frac{1}{n} \sum_{s=1}^K \sum_{x^i \in X_s} \rho(x^i, c^s) = \Psi(\mathcal{A}).$$

Для доказательства нашего утверждения достаточно показать, что для разбиения $\mathcal{A}_2(X) = \{X_1^2, \dots, X_K^2\}$, порожденного последовательностью наборов C , верно $\Psi(\mathcal{A}_2) \leq \Psi(\mathcal{A})$ для всех $\mathcal{A} \in \mathcal{O}_K(X)$.

Действительно, если это так, то найдется разбиение $\mathcal{A}(X) = \{X_1, \dots, X_K\}$, для которого верно неравенство

$$\Psi(\mathcal{A}_2) = \frac{1}{n} \sum_{s=1}^K \sum_{x^i \in X_s^2} \rho(x^i, c^s) > \frac{1}{n} \sum_{s=1}^K \sum_{x^i \in X_s} \rho(x^i, c^s) = \Psi(\mathcal{A}).$$

Тогда можно отыскать объект $x^i \in X$, принадлежащий в разбиении $\mathcal{A}_2(X)$ некоторому классу X_s^2 , а в разбиении $\mathcal{A}(X)$ - классу X_t , для которого $\rho(x^i, c^s) > \rho(x^i, c^t)$. С другой стороны, так как разбиение $\mathcal{A}_2(X)$ порождено последовательностью наборов C , объект $x^i \in X_s^2$ удовлетворяет неравенству $\rho(x^i, c^s) \leq \rho(x^i, c^t)$. Из полученного противоречия следует, что $\Psi(\mathcal{A}_2) \leq \Psi(\mathcal{A})$ для всех $\mathcal{A} \in \mathcal{O}_K(X)$.

Из приведенных выше рассуждений следует:

I) если разбиение $\mathcal{A}(X)$ с центрами классов $C = \{c^1, \dots, c^K\}$ является оптимальным на множестве $\mathcal{O}_K(X)$, то оно порождается последовательностью наборов C , и любое разбиение $\mathcal{A}'(X)$, порожденное последовательностью наборов C , оптимально на множестве

$\alpha_K(X)$;

2) справедливо равенство

$$\min_{A \in \alpha_K(X)} \Phi(A) = \min_C \Phi(A_C),$$

где C пробегает множество всевозможных последовательностей наборов из множества P^m и A_C - разбиение, порожденное последовательностью наборов C .

Последнее утверждение весьма полезно для нахождения оптимального разбиения в случае, когда число объектов велико по сравнению с числом признаков, числом значений признаков и числом классов. Например, если признаки - дихотомические, то число всевозможных наборов последовательностей K наборов C равно 2^{Km} , тогда как число всех разбиений $2^{n \log_2 K}$.

Целью дальнейшего рассмотрения является установление связи между решением задачи о построении оптимального разбиения на множестве признаков T_1, \dots, T_m и решением той же задачи на некотором подмножестве этого множества.

Для множеств натуральных чисел

$L = \{p_1, \dots, p_\ell \mid p_1 < \dots < p_\ell\}$ и $H = \{q_1, \dots, q_{m-\ell} \mid q_1 < \dots < q_{m-\ell}\}$ таких, что $L \cap H = \emptyset$ и $L \cup H = \{1, \dots, m\}$, определим на множестве P^m отображения φ_L и φ_H следующим образом: для набора $a = (a_1, \dots, a_m) \in P^m$ положим $\varphi_L(a) = (a_{p_1}, \dots, a_{p_\ell})$ и $\varphi_H(a) = (a_{q_1}, \dots, a_{q_{m-\ell}})$. Для объекта $x^i = (x_1^i, \dots, x_m^i) \in X$ положим $\varphi_L(x^i) = (x_{p_1}^i, \dots, x_{p_\ell}^i)$. Образ множества X при отображении φ_L назовем L -редукцией множества X . Напомним, что на множестве X объекты x^s и x^t различны, если $s \neq t$. При отображении φ_L объекты сохраняют свои порядковые номера, и если $x^s \neq x^t$, т.е. $s \neq t$, то $\varphi_L(x^s) \neq \varphi_L(x^t)$. Поэтому на множестве X отображение φ_L - взаимно-однозначно. Следовательно, на множестве $\varphi_L(X)$ можно определить отображение φ_L^{-1} : $\varphi_L^{-1}(\tilde{x}^i) = x^i$, если $\tilde{x}^i = \varphi_L(x^i)$. Переход от множества X к множеству $\varphi_L(X)$ означает исключение из рассмотрения признаков $T_{q_1}, \dots, T_{q_{m-\ell}}$.

На множестве $P^\ell = \varphi_L(P^m)$ редуцированных наборов и множестве $\varphi_L(X)$ редуцированных объектов так же, как на множествах P^m и X соответственно, вводятся функционал ρ , понятия центра множества, разбиения и степени неоднородности. Таким образом, для любой редукции можно поставить задачу оптимального разбиения.

Для произвольных наборов $a = (a_1, \dots, a_m)$, $b = (b_1, \dots, b_m) \in P^m$ имеем

$$\begin{aligned} m\rho(a, b) &= \sum_{j=1}^m \varepsilon_j(a_j, b_j) = \sum_{j \in L} \varepsilon_j(a_j, b_j) + \sum_{j \in H} \varepsilon_j(a_j, b_j) = \\ &= \ell \cdot \rho(\varphi_L(a), \varphi_L(b)) + (m - \ell) \rho(\varphi_H(a), \varphi_H(b)). \end{aligned}$$

Из этого равенства вытекает следующая

Л е м м а 1. Набор C является центром множества $X_0 \subseteq X$ тогда и только тогда, когда $\varphi_L(C)$ - центр множества $\varphi_L(X_0)$ и $\varphi_H(C)$ - центр множества $\varphi_H(X_0)$.

Для разбиения $\mathcal{A}(X) = \{X_1, \dots, X_K\}$ и множества $L \subseteq \{1, \dots, m\}$ через $\varphi_L(\mathcal{A})$ обозначим новое разбиение $\varphi_L(\mathcal{A}) = \{\varphi_L(X_1), \dots, \varphi_L(X_K)\}$ и соответственно $\varphi_L^{-1}(\tilde{\mathcal{A}}) = \{\varphi_L^{-1}(\tilde{X}_1), \dots, \varphi_L^{-1}(\tilde{X}_K)\}$, где $\tilde{\mathcal{A}} = \{\tilde{X}_1, \dots, \tilde{X}_K\}$.

Л е м м а 2. Для произвольного разбиения $\mathcal{A}(X)$ и разбиений $\mathcal{A}_1 = \varphi_L(\mathcal{A})$ и $\mathcal{A}_2 = \varphi_H(\mathcal{A})$ верно равенство $m \Phi(\mathcal{A}) = \ell \cdot \Phi(\mathcal{A}_1) + (m - \ell) \Phi(\mathcal{A}_2)$.

Д о к а з а т е л ь с т в о. Пусть классы разбиения $\mathcal{A}(X) = \{X_1, \dots, X_K\}$ имеют центры C^1, \dots, C^K . По определению степени неоднородности, имеем

$$\begin{aligned} m \Phi(\mathcal{A}) &= \frac{1}{n} \sum_{s=1}^K \sum_{x^i \in X_s} m \rho(x^i, C^s) = \\ &= \frac{1}{n} \sum_{s=1}^K \sum_{x^i \in X_s} [\ell \rho(\varphi_L(x^i), \varphi_L(C^s)) + (m - \ell) \rho(\varphi_H(x^i), \varphi_H(C^s))] = \\ &= \frac{\ell}{n} \sum_{s=1}^K \sum_{\varphi_L(x^i) \in \varphi_L(X_s)} \rho(\varphi_L(x^i), \varphi_L(C^s)) + \\ &+ \frac{m - \ell}{n} \sum_{s=1}^K \sum_{\varphi_H(x^i) \in \varphi_H(X_s)} \rho(\varphi_H(x^i), \varphi_H(C^s)) = \ell \cdot \Phi(\mathcal{A}_1) + (m - \ell) \Phi(\mathcal{A}_2). \end{aligned}$$

Лемма доказана.

Назовем степенью K -неоднородности множества X величину

$$\Phi_K(X) = \min_{\mathcal{A} \in \alpha_K(X)} \Phi(\mathcal{A}).$$

Заметим, что степень 1-неоднородности - это ранее введенная степень неоднородности множества X :

$$\Phi_1(X) = \Phi(X) = \frac{1}{n} \sum_{x^i \in X} \rho(x^i, C),$$

где C - центр множества X .

Справедливы следующие леммы.

Л е м м а 3. Если набор $C \in P^m$ является центром каждого класса X_s , $s = 1, \dots, K$ разбиения $\mathcal{A}(X) = \{X_1, \dots, X_K\}$, то C - центр множества X и $\Phi(\mathcal{A}) = \Phi(X)$.

Л е м м а 4. Для любого натурального K и любого разбиения $\mathcal{A} \in \alpha_K(X)$ верно неравенство $\Phi_K(X) \leq \Phi(\mathcal{A}) \leq \Phi(X)$.

Т е о р е м а 1. Для любого натурального K и любого множества X объектов верно неравенство

$$(m - \ell) \Phi_K(\varphi_H(X)) \leq m \Phi_K(X) - \ell \Phi_K(\varphi_L(X)) \leq (m - \ell) \Phi(\varphi_H(X)).$$

Д о к а з а т е л ь с т в о. I. Пусть разбиение $\mathcal{A}(X)$ оптимально на множестве $\mathcal{A}(X)$ и $\mathcal{A}_1 = \varphi_L(\mathcal{A})$, $\mathcal{A}_2 = \varphi_H(\mathcal{A})$. Тогда из лемм 2 и 4 получаем

$$m \Phi_K(X) = m \Phi(\mathcal{A}) = \ell \Phi(\mathcal{A}_1) + (m - \ell) \Phi(\mathcal{A}_2) \geq \ell \Phi_K(\varphi_L(X)) + (m - \ell) \Phi_K(\varphi_H(X)).$$

2. Пусть разбиение \mathcal{A}_1 оптимально на $\mathcal{A}_K(\varphi_L(X))$ и $\mathcal{A}(X) = \varphi_L^{-1}(\mathcal{A}_1)$, $\mathcal{A}_2 = \varphi_H(\mathcal{A})$. Тогда

$$m \Phi_K(X) \leq m \Phi(\mathcal{A}) = \ell \Phi(\mathcal{A}_1) + (m - \ell) \Phi(\mathcal{A}_2) \leq \ell \cdot \Phi_K(\varphi_L(X)) + (m - \ell) \Phi(\varphi_H(X)).$$

Теорема доказана.

С л е д с т в и е I. Пусть $L = \{p_1, \dots, p_m\} \subset \{1, \dots, m\}$;

$H_i = \{i\}$, $\varphi_i = \varphi_{H_i}$ для $i \notin L$. Тогда для любого K верно неравенство

$$0 \leq m \Phi_K(X) - \ell \Phi_K(\varphi_L(X)) \leq \sum_{i \notin L} \Phi(\varphi_i(X)).$$

С л е д с т в и е 2. Пусть разбиение \mathcal{A} , оптимально на множестве $\mathcal{A}_K(\varphi_L(X))$ и $\mathcal{A}(X) = \varphi_L^{-1}(\mathcal{A})$. Тогда

$$0 \leq \Phi(\mathcal{A}) - \Phi_K(X) \leq \frac{m - \ell}{m} [\Phi(\varphi_H(X)) - \Phi_K(\varphi_H(X))].$$

Теорема и следствия из нее дают возможность оценить степень неоднородности разбиения, оптимального на $\mathcal{A}_K(X)$, и построить приближенное решение задачи для множества признаков T_1, \dots, T_m по степени неоднородности разбиения, оптимального на $\mathcal{A}_K(\varphi_L(X))$, т.е. по решению этой же задачи для признаков $T_{p_1}, \dots, T_{p_\ell}$.

Рассмотрим случай, когда по разбиению, оптимальному на $\mathcal{A}_K(\varphi_L(X))$, можно точно определить разбиение, оптимальное на $\mathcal{A}_K(X)$.

Т е о р е м а 2. Пусть $\mathcal{A}(X)$ — разбиение, оптимальное на множестве $\mathcal{A}_K(X)$, с такими центрами классов C^1, \dots, C^K , что для каждого $i \in H$ и $z = 1, \dots, K$ верно равенство $C_i^z = C_i^1$. Тогда для L -редукции $\tilde{X} = \varphi_L(X)$ выполняются условия:

- 1) разбиение $\mathcal{A}_1 = \varphi_L(\mathcal{A})$ оптимально на множестве $\mathcal{A}_K(\tilde{X})$;
- 2) для любого разбиения \mathcal{A}'_1 , оптимального на множестве $\mathcal{A}_K(\tilde{X})$, разбиение $\mathcal{A}'(X) = \varphi_L^{-1}(\mathcal{A}'_1)$ оптимально на множестве $\mathcal{A}_K(X)$.

Д о к а з а т е л ь с т в о. Пусть \mathcal{A}'_1 — произвольное разбиение множества \tilde{X} , $\mathcal{A}' = \varphi_L^{-1}(\mathcal{A}'_1)$, $\mathcal{A}_2 = \varphi_H(\mathcal{A})$ и $\mathcal{A}'_2 = \varphi_H(\mathcal{A}'_1)$. Наборы $\varphi_H(C^1), \dots, \varphi_H(C^K)$, по лемме I, являются центрами классов разбиения \mathcal{A}_2 , и, по условию теоремы, для всех $z = 1, \dots, K$ имеем $\varphi_H(C^z) = \varphi_H(C^1)$. Тогда из лемм 3 и 4 получаем, что $\Phi(\mathcal{A}_2) = \Phi(\varphi_H(X)) \geq \Phi(\mathcal{A}'_2)$. С другой стороны, $\Phi(\mathcal{A}) \leq \Phi(\mathcal{A}_2)$, откуда

$$m \Phi(\mathcal{A}) = \ell \Phi(\mathcal{A}_1) + (m - \ell) \Phi(\mathcal{A}_2) \leq \ell \Phi(\mathcal{A}'_1) + (m - \ell) \Phi(\mathcal{A}'_2) = m \Phi(\mathcal{A}').$$

Следовательно, $\Phi(\mathcal{A}_1) \leq \Phi(\mathcal{A}'_1)$, т.е. разбиение \mathcal{A}_1 оптимально на множестве $\mathcal{A}_K(\tilde{X})$.

Если разбиение \mathcal{A}'_1 оптимально на $\mathcal{A}_K(\tilde{X})$, т.е. $\Phi(\mathcal{A}_1) = \Phi(\mathcal{A}'_1)$, то из неравенства $\Phi(\mathcal{A}_2) \geq \Phi(\mathcal{A}'_2)$ получаем

$$m \Phi(\mathcal{A}) = \ell \Phi(\mathcal{A}_1) + (m - \ell) \Phi(\mathcal{A}_2) \geq \ell \Phi(\mathcal{A}_1) + (m - \ell) \Phi(\mathcal{A}'_2) = m \Phi(\mathcal{A}').$$

Следовательно, \mathcal{A}' оптимально на множестве $\mathcal{A}_K(X)$.

Теорема доказана.

Л е м м а 5. Если разбиение $\mathcal{A}(X) = \{X_1, \dots, X_K\}$ порождено наборами $a^1, \dots, a^K \in P^m$ и для всех $s = 1, \dots, K$ и $i \in N$ выполняется равенство $a^s = a^i$, то разбиение $\mathcal{A}_1 = \varphi_L(\mathcal{A})$ порождается наборами $\varphi_L(a^1), \dots, \varphi_L(a^K)$.

Д о к а з а т е л ь с т в о. Условие леммы эквивалентно следующему утверждению: для любых целых s, t ($1 \leq s, t \leq K$) и любого объекта $x^i \in X_s$ выполняются соотношения $\rho(x^i, a^s) \leq \rho(x^i, a^t)$, $\varphi_N(a^s) = \varphi_N(a^t)$. Надо показать, что для любых целых s, t ($1 \leq s, t \leq K$) и любого объекта $\tilde{x}^i \in \varphi_L(X_s)$ выполнено неравенство $\rho(\tilde{x}^i, \varphi_L(a^s)) \leq \rho(\tilde{x}^i, \varphi_L(a^t))$. Пусть для произвольного фиксированного s ($1 \leq s \leq K$) объект $\tilde{x}^i \in \varphi_L(X_s)$ и $x^i = \varphi_L^{-1}(\tilde{x}^i)$. Тогда, по определению множества $\varphi_L(X_s)$, имеем $x^i \in X_s$. Поэтому для любого $t = 1, \dots, K$ выполняется неравенство $\rho(x^i, a^s) \leq \rho(x^i, a^t)$. Отсюда получаем

$$\begin{aligned} m \rho(x^i, a^t) &= \ell \rho(\tilde{x}^i, \varphi_L(a^t)) + (m - \ell) \rho(\varphi_N(x^i), \varphi_N(a^t)) = \\ &= \ell \rho(\tilde{x}^i, \varphi_L(a^t)) + (m - \ell) \rho(\varphi_N(x^i), \varphi_N(a^1)). \end{aligned}$$

Поэтому $\rho(x^i, a^t) - \rho(x^i, a^s) = \frac{\ell}{m} [\rho(\tilde{x}^i, \varphi_L(a^t)) - \rho(\tilde{x}^i, \varphi_L(a^s))]$.

Следовательно, $\rho(\tilde{x}^i, \varphi_L(a^s)) \leq \rho(\tilde{x}^i, \varphi_L(a^t))$.

Лемма доказана.

Т е о р е м а 3. Пусть $\mathcal{A}(X)$ — разбиение, оптимальное на $\alpha_K(X)$ и с такими центрами классов C^1, \dots, C^K , что для каждого $i \in N$ и $s = 1, \dots, K$ верно равенство $C_i^s = C_i^1$. Пусть $\tilde{X} = \varphi_L(X)$ и некоторое разбиение $\tilde{\mathcal{A}}(\tilde{X})$ с центрами классов $\tilde{a}^1, \dots, \tilde{a}^K$ оптимально на $\alpha_K(\tilde{X})$. Тогда любое разбиение $\mathcal{A}'(X)$, порожденное такими наборами $a^1, \dots, a^K \in P^m$, что для всех $s = 1, \dots, K$ верно $\varphi_L(a^s) = \tilde{a}^s$ и для всех $i \in N$ выполняется равенство $a^s = a^i$, является оптимальным на множестве $\alpha_K(X)$.

Д о к а з а т е л ь с т в о. Разбиение $\mathcal{A}'_1 = \varphi_L(\mathcal{A}')$, по лемме 5, порождено наборами $\varphi_L(a^1), \dots, \varphi_L(a^K)$, являющимися центрами классов разбиения $\tilde{\mathcal{A}}(\tilde{X})$, оптимального на $\alpha_K(\tilde{X})$. Из результатов § 2 вытекает, что разбиение \mathcal{A}'_1 также оптимально на множестве $\alpha_K(\tilde{X})$. Согласно теореме 2, получаем, что разбиение $\mathcal{A}_1 = \varphi_L(\mathcal{A}'_1)$ оптимально на множестве $\alpha_K(\tilde{X})$, следовательно, $\Phi(\mathcal{A}_1) = \Phi(\mathcal{A}'_1)$. С другой стороны, так как центрами классов разбиения $\varphi_N(\mathcal{A})$ являются наборы $\varphi_N(C^1), \dots, \varphi_N(C^K)$, а по условию теоремы для всех $s = 1, \dots, K$ выполняется равенство $\varphi_N(C^s) = \varphi_N(C^1)$, то, по леммам 3 и 4, имеем

$$\Phi(\varphi_N(\mathcal{A})) = \Phi(\varphi_N(X)) \geq \Phi(\varphi_N(\mathcal{A}'_1)).$$

Отсюда получаем

$$\begin{aligned} m \Phi(\mathcal{A}') &= \ell \Phi(\mathcal{A}'_1) + (m - \ell) \Phi(\varphi_N(\mathcal{A}'_1)) \leq \\ &\leq \ell \Phi(\mathcal{A}_1) + (m - \ell) \Phi(\varphi_N(\mathcal{A})) = m \Phi(\mathcal{A}). \end{aligned}$$

Так как разбиение \mathcal{A} , по условию теоремы, оптимально на множестве $\mathcal{A}_K(X)$, то разбиение \mathcal{A}' оптимально на $\mathcal{A}_K(X)$.

Теорема доказана.

Поступила в ред.-изд.отдел.

12 февраля 1979 г.

Л и т е р а т у р а

1. Дюран Б., Одея П. Кластерный анализ.-М.: Статистика, 1977. - 128 с.

2. Ту Дж., Гонсалес Р. Принципы распознавания образов.- М.: Мир, 1978. - 411 с.