

ОБ ОДНОМ МЕТОДЕ ТАКСОНОМИИ МНОЖЕСТВ ОБЪЕКТОВ И ПАРАМЕТРОВ

В.И. Котиков

§ 1. Постановка задачи

Пусть дано M множеств $\{L_1, \dots, L_M\}$. Каждое множество L_i содержит N_i объектов, где $N_i > 1$ и $\sum_{i=1}^M N_i = N_0$. Каждый объект x_{α} , в свою очередь, представляет собой определенную точку в исходном p -мерном пространстве его описания $x_{\alpha} = \{x_{\alpha 1}, \dots, x_{\alpha p}\}$. Множество $\{L_i\}$ не содержит общих объектов.

Необходимо M множеств $\{L_i\}$ разбить на K таксонов (классов, групп), причем, каждое из множеств L_i должно входить только в один из K таксонов. $1 < K < M$. Эти "упаковки" множества (таксоны) будем обозначать $\{T_1, \dots, T_K\}$.

§ 2. Критерий качества таксономии

Определим сначала "таксономичность" (возможность объединения) - t_{ij} для любой пары множеств $\{L_i, L_j\}$.

При определении t_{ij} мы будем находить из следующих двух интуитивно понятных требований:

а) множества L_i и L_j должны быть достаточно плохо "распознаваемы" ("отличимы") друг от друга (в этом случае величина t_{ij} будет достаточно большой);

б) множества L_i и L_j должны быть достаточно "похожими" друг на друга.

Как будет видно из дальнейшего, требования а) и б) не являются тавтологией друг друга.

Распознаваемость t_{ij} множеств L_i и L_j мы будем определять величиной критерия Фишера $((\mu_i - \mu_j)^2 / (\sigma_i^2 + \sigma_j^2))$ по вектору

$Y = \sum_{k=1}^p \lambda_k X_k$ в исходном пространстве $X = \{X_1, \dots, X_p\}$, который максимизирует данный критерий. Величинам μ и σ — есть соответствующие оценки математического ожидания и дисперсии множества. Если мы на основании множеств L_i и L_j составим матрицу ковариаций $\|V_{kq}\|$ ($k, q = 1, \dots, p$), где

$$V_{kq} = \frac{(\mu_{ki} - \mu_{kj})(\mu_{qi} - \mu_{qj})}{\sigma_{kqi} + \sigma_{kqj}},$$

то нетрудно доказать, что вектор Y , максимизирующий критерий Фишера, есть вектор, соответствующий максимальному собственному числу $\lambda_{\max}$ матрицы $\|V_{kq}\|$. При этом

$$\gamma_{ij} = \lambda_{\max}(V) = \left(\frac{(\mu_i - \mu_j)^2}{\sigma_i + \sigma_j} \right)_{\max}.$$

Обозначим (похожесть) C_{ij} множеств L_i и L_j определим так. Допустим, что $\lambda_{\min}(L_i)$, $\lambda_{\min}(L_j)$ и $\lambda_{\min}(L_i \cup L_j)$ — минимальные собственные числа матриц ковариаций, полученных по объектам множеств L_i , L_j и $(L_i \cup L_j)$ соответственно. Можно доказать, что $\lambda_{\min}(L_i)$ — есть остаточная дисперсия при аппроксимации точек множества L_i линейным регрессионным полиномом по методу наименьших квадратов в модели X .

Пусть $\lambda_{\min}(L_i, L_j) = \min\{\lambda_{\min}(L_i), \lambda_{\min}(L_j)\}$, тогда величина $C_{ij} = \lambda_{\min}(L_i, L_j) / \lambda_{\min}(L_i \cup L_j)$ будет определять степень ухудшения описания в пространстве X множеств L_i и L_j при их объединении. Если множества L_i и L_j "похожи" друг на друга, то величина C_{ij} будет достаточно большой.

Введем также и весовой коэффициент $(N_i + N_j) / N_0$, характеризующий степень доверия к полученным оценкам γ_{ij} и C_{ij} .

Таким образом, величина t_{ij} определяется так:

$$t_{ij} = \frac{N_0 \cdot \lambda_{\min}(L_i, L_j)}{(N_i + N_j) \cdot \lambda_{\max}(V) \cdot \lambda_{\min}(L_i \cup L_j)}.$$

Очевидно, что $t_{ij} = t_{ji}$.

На основании обучающей выборки определяется матрица $\|t_{ij}\|$; $i, j = 1, \dots, M$. Пусть $t_{ii} \neq 0$.

Определить качество таксономии F в целом можно с помощью, например, одного из следующих двух различных критериев.

1. Квазиминимаксный критерий.

$$F_1 = \sum_{i=1}^M \sum_{j=1}^M \max(t_{ij}),$$

где: $L_i \subset T_e \wedge L_j \subset T_e$; $i \neq j$; $i, j = 1, \dots, M$.

2. Квазифишеров (уровнежный) критерий.

$$F_2 = \sum_{i=1}^M \sum_{j=1}^{M-1} \sum_{k=1}^M t_{ij},$$

где: $L_i \subset T_e \wedge L_j \subset T_e$ и $i \neq j$.

§ 3. Алгоритмы решения задачи

Алгоритм 1.

1. Пусть $T_i = L_i$; $i = 1, \dots, M$.

2. Множества L_i и L_j , не входящие ещё в один таксон, для которых величина t_{ij} максимальна, объединяются в один таксон T_{ij} .

3. Если два таксона T_{ij} и T_{kl} имеют хотя бы один общий индекс, то они объединяются в один таксон T_{ijkl} .

4. Если число таксонов больше K , то переходим к пункту 2. Очевидно, что алгоритм 1 максимизирует критерий F_1 .

Алгоритм 2.

Введем матрицу неизвестных $\|Z_{cij}\|$ ($c = 1, \dots, K$; $i, j = 1, \dots, M$). Целевая функция:

$$F_2 = \sum_{c=1}^K \sum_{i=1}^{M-1} \sum_{j=i+1}^M t_{ij} Z_{cij}; \quad Z_{cij} = \{0, 1\}.$$

Ограничения:

$$\sum_{i=1}^M z_{li} \geq 1; \quad l=1, \dots, K;$$

$$\sum_{l=1}^K z_{li} = 1; \quad i=1, \dots, M;$$

$$z_{li} - \frac{1}{M-K+2} \left(\sum_{j=1}^M z_{lj} + \sum_{j=1}^i z_{ji} \right) \geq 0; \quad l=1, \dots, K; \quad i=1, \dots, M.$$

Это задача целочисленного линейного программирования, решение которой максимизирует критерий F_2 .

§ 4. Таксономия параметров

Часто возникает задача таксономии (группировки) исходных параметров (признаков) $\{X_1, \dots, X_p\}$ на K непересекающихся таксонов (групп). В основу, как и в других работах, может быть взята, например, матрица коэффициентов корреляций $\| \gamma_{ij} \|$ ($i, j = 1, \dots, p$) между признаками $\{X_i\}$. Положив $(M=p, L_i=X_i, t_{ij}=\gamma_{ij})$, мы тем самым, свели данную задачу к предыдущей. В этом случае можно пользоваться также критериями F_1 или F_2 и соответствующими алгоритмами.