

Удк 519.95:681.3.06

ОБ ИСПОЛЬЗОВАНИИ МАТРИЦ СВЯЗИ ДЛЯ ОДНОВРЕМЕННОГО АНАЛИЗА НОМИНАЛЬНЫХ И КОЛИЧЕСТВЕННЫХ ПРИЗНАКОВ

Б.Г. Миркин

Для анализа качественных признаков автором было предложено [1-3] использовать язык булевских матриц между объектами, что вызвало появление новых методов [1] анализа данных, в том числе методов одновременного анализа признаков, измеренных в количественных и качественных шкалах [2]. В настоящей работе, следуя [3], рассмотрены некоторые теоретические аспекты данного направления.

На множестве N объектов, занумерованных индексами $1, 2, \dots, N$, рассмотрим совокупность n признаков $x^1, \dots, x^n$, каждый из которых измерен в количественной или номинальной шкале (ранговые признаки сводят к количественным приписыванием стандартных рангов, соответствующих отдельным местам).

Каждый номинальный признак x охарактеризуем квадратной $N \times N$ -матрицей $r = (r_{ij})$ с элементами, равными

$$r_{ij} = \begin{cases} 0, & \text{если } x(i) = x(j), \\ 1, & \text{если } x(i) \neq x(j), \end{cases}$$

где $x(i)$ - значение признака x на i -м объекте. Для количественного признака x рассмотрим квадратную $N \times N$ -матрицу $x = (x_{ij})$, где $x_{ij} = (x_i - x_j)^2$. Мы рассматриваем не $x_i - x_j$, как в [4,5], а $(x_i - x_j)^2$, поскольку, во-первых, необходимо, как и в номинальном случае, иметь симметричную матрицу для равноправия обоих типов шкал и, во-вторых, квадраты разностей - стандартная характеристика, используемая для математического анализа моделей линейной статистики.

Используя матричный способ представления данных, можно рассматривать методы компонентного и регрессионного анализа, как модели аппроксимации, полностью аналогичные аппроксимационным пост-

роениям метода наименьших квадратов применительно к обычным количественным признакам. При этом основную роль играют скалярные произведения и коэффициенты корреляции матриц связи, рассматриваемых как вектора $N \times N$ -мерного пространства.

Для вычисления коэффициента корреляции матричного представления количественных признаков x и y обозначим через μ_{k1} обычные центральные смешанные моменты $\mu_{k1} = E((x - E_x)^k (y - E_y)^1)$, где E - операция взятия среднего значения.

Как известно, μ_{20} и μ_{02} - дисперсии x и y соответственно, μ_{11} - коэффициент ковариации, а $\mu_{11} / \sqrt{\mu_{20} \mu_{02}}$ - коэффициент корреляции.

Обозначим через M_{k1} центральные моменты матричных представлений x и y . Нетрудно видеть, что среднее значение матрицы связи равно удвоенной дисперсии:

$$\frac{1}{N^2} \sum_{i,j} (x_i - x_j)^2 = \frac{2}{N} \sum_i (x_i - \frac{1}{N} \sum_j x_j)^2 = 2\mu_{20}.$$

Аналогично дисперсии M_{20} и M_{02} матричных представлений могут быть выражены через моменты четвертого порядка:

$$M_{20} = 2(\mu_{40} + \mu_{20}^2), \quad M_{02} = 2(\mu_{04} + \mu_{02}^2).$$

Матричный коэффициент ковариации имеет вид

$$M_{11} = 2(\mu_{22} + 2\mu_{11}^2 - \mu_{20}\mu_{02}),$$

так что коэффициент корреляции матриц равен

$$\rho = \frac{M_{11}}{\sqrt{M_{20} M_{02}}} = \frac{\mu_{22} + 2\mu_{11}^2 - \mu_{20} \mu_{02}}{\sqrt{(\mu_{40} + \mu_{20}^2)(\mu_{04} + \mu_{02}^2)}}. \quad (1)$$

Можно проверить, что коэффициент (1) равен 1 тогда и только тогда, когда $y = \alpha x + \beta$.

Пусть теперь x и y - номинальные признаки с матрицами $r = (r_{ij})$ и $q = (q_{ij})$ соответственно. Среднее значение матрицы r выражается через распределение $(p_1, \dots, p_n)$ значений признака x в виде $\delta(x) = 1 - \sum_i p_i^2$, что равно качественной дисперсии номинального признака и равносильно вероятности ошибки пропорционального прогноза значений x (см. [1]).

Обозначим через $R = \{R_1, \dots, R_m\}$ разбиение множества объектов при признаку x . Нетрудно видеть, что скалярное произведение матриц r и q равно

$$(r, q) = \sum_{i,j} q_{ij} = \sum_{s=1}^m \sum_{i,j \in R_s} q_{ij} = N^2 [\delta(y) - \sum_{s=1}^m p_s^2 \delta(y/s)], \quad (2)$$

где $\delta(y/s) = 1 - \sum_t \left(\frac{p_{st}}{p_s} \right)^2$, причем p_{st} — доля объектов, имеющих s -ю градацию x и t -ю градацию y одновременно, так что $p_s = \sum_t p_{st}$.

Величина $\delta(y/s)$ характеризует среднюю ошибку пропорционального прогноза значений y при заданном s (см. [1]).

Тогда коэффициент ковариации матричных представлений признаков x и y равен

$$\frac{1}{N^2} (r, q) - \delta(x) \cdot \delta(y) = \delta(y) (1 - \delta(x)) - \sum_{s=1}^m p_s^2 \delta(y/s). \quad (3)$$

Следовательно, коэффициент корреляции матричных представлений номинальных признаков есть

$$\rho = \frac{\delta(y)(1-\delta(x)) - \sum_{s=1}^m p_s^2 \delta(y/s)}{\sqrt{\delta(x)(1-\delta(y)) \delta(y)(1-\delta(x))}}, \quad (4)$$

что близко к формуле, предложенной в [5].

Коэффициент ковариации количественного признака y с номинальным признаком x равен

$$\frac{1}{N^2} \sum_{i,j} r_{ij} \cdot y_{ij} - 2\delta(x)\sigma^2(y) = 2[\sigma^2(y)(1-\delta(x)) - \sum_{s=1}^m p_s^2 \sigma_s^2(y)], \quad (5)$$

где σ_s^2 — дисперсия признака y в классе R_s , отвечающем s -му значению признака x .

Следовательно, коэффициент корреляции номинального x и количественного y равен

$$\rho = \frac{\mu_{02}(1-\delta(x)) - \sum_{s=1}^m p_s^2 \sigma_s^2(y)}{\sqrt{\frac{1}{2} \delta(x)(1-\delta(x)) (\mu_{04} + \mu_{02}^2)}}. \quad (6)$$

Формулы (1), (4) и (6) задают коэффициенты связи между номинальными и количественными признаками.

Рассмотрим теперь задачу конструирования номинального фактора: максимизировать суммарный коэффициент ковариации

$$\sum_{k=1}^n (a^k, r) = (a, r) \quad (7)$$

по всем матрицам r , соответствующим разбиениям множества объектов. Здесь a^k - центрированная матрица признака x^k , r - центрированная матрица искомого разбиения $R \in (R_1, \dots, R_n)$, а $a = \sum_k a^k$ -

суммарная матрица связей между объектами.

УТВЕРЖДЕНИЕ 1. Задача максимизации (7) эквивалентна задаче максимизации суммы связей внутри классов R за вычетом порога $\bar{a}$, равного в данном случае среднему значению связей a_{ij} (см. [3]), т.е.

$$f(R) = \sum_{i=1}^n \sum_{j \in R_i} (a_{ij} - \bar{a}). \quad (8)$$

Методы решения задачи (8) описаны в [1].

Аналогично можно сформулировать задачу о конструировании количественного фактора x , максимизирующего функцию

$$\sum_{k=1}^n (a^k, x) = \sum_{i,j=1}^N a_{ij} (x_i - x_j)^2. \quad (9)$$

Поскольку функция (9) не зависит от среднего значения x , будем считать его нулевым, т.е. вести максимизацию только по центрированным x . Для корректности задачи (9) необходимо также масштабировать условие. Потребуем, чтобы дисперсия x была постоянна:

$$\sum_{i=1}^N x_i^2 = \text{const}. \quad (10)$$

Дифференцируя функцию Лагранжа задачи (9)-(10) по искомым x_k , получаем следующее

УТВЕРЖДЕНИЕ 2. Количественный фактор в смысле (9)-(10) для произвольной матрицы $a = (a_{ij})$ связей между объектами

конструируется как собственный вектор соответствующие симметрированной и центрированной матрицы A с элементами $a_{ij} + a_{ji}$ при $i \neq j$ и $-\sum_{k \neq i} (a_{ik} + a_{ki})$ при $i = j$, соответствующий ее максимальному собственному значению.

Это утверждение можно рассматривать как некоторое обоснование известных эвристических рекомендаций о нахождении "весов" объектов как компонент собственного вектора, соответствующего максимальному собственному числу матрицы связи.

В целом полученные результаты свидетельствуют о естественности предложенных процедур и возможности их использования.

Л и т е р а т у р а

1. МИРКИН Б.Г. Анализ качественных признаков. -М.: Статистика. 1976. - 166 с.
2. МИРКИН Б.Г., ВЫСОЦКАЯ Н.В. и др. Шкалы упорядочения. -В кн.: Моделирование в экономических исследованиях. Новосибирск, 1978, с. 109-119.
3. МИРКИН Б.Г. Об учете признаков разных типов шкал в линейных моделях анализа данных. -В кн.: Математические вопросы анализа данных. Новосибирск, 1980, с.20-31.
4. КЕНДЭЛ М.Дж. Ранговые корреляции. -М.: Статистика. 1975. - 214 с.
5. КУПЕРИТОВ В.Л., ПОЛИЩУК Л.И., ТРОФИМОВ В.А. Коэффициенты корреляций связей между объектами. -В кн.: Модели агрегирования социально-экономической информации. Новосибирск, 1978, с.17-34.

Поступила в ред.-изд.отд.
20 февраля 1981 года