

## Статистическая групповая классификация в случае многомерного распределения Пуассона

Каменева Светлана Владимировна, старший преподаватель,  
Пермский государственный научно-исследовательский университет, г. Пермь

**Аннотация.** В данной статье представлены методы групповой и поточечной классификации, позволяющие исследовать вероятностные модели многомерных дискретных распределений. Построены оптимальные решающие правила для многомерного распределения Пуассона. В качестве частных случаев приведены решающие правила поточечной классификации объектов из данных совокупностей. Рассмотрены статистические решающие правила групповой классификации, построенные на основе оценок максимального правдоподобия и несмещенных оценок.

**Ключевые слова:** дискретные распределения, многомерное распределение Пуассона, статистическая групповая классификация, оценки максимального правдоподобия, несмещенные оценки.

На практике широкое применение имеет распределение Пуассона. Изучению его посвящено большое количество работ [1], [2], [3].

Распределение Пуассона является идеальной моделью для описания процесса радиоактивного распада. Радиоактивное вещество испускает альфа - частицы. Случайная величина - число частиц, достигающих заданной части пространства (счетчика) в течение времени  $\tau$  - имеет распределение Пуассона [4].

Дискретная, случайная величина  $X$ , принимающая целые неотрицательные значения  $x = 0, 1, 2, \dots$  в соответствии с некоторым значением  $\tau$  - временем наблюдения потока событий, имеет распределение Пуассона, когда вероятность  $P_\lambda(X = x | \tau)$  определяется формулой

$$P_\lambda(X = x | \tau) = \frac{(\tau\lambda)^x}{x!} e^{-\tau\lambda}, \quad (1)$$

где  $\lambda$  - параметр распределения Пуассона.

На практике обычно рассматривают распределение Пуассона с фиксированным временем  $\tau$  ( $\tau = 1$ ), которое задается соотношением

$$P_\lambda(X = x) = \frac{\lambda^x}{x!} e^{-\lambda}. \quad (2)$$

Математическое ожидание и дисперсия распределения Пуассона (2) совпадают

$$M_\lambda(X) = D_\lambda(X) = \lambda.$$

Обобщением на многомерный случай распределения (2) является многомерное распределение Пуассона. Для него вероятность того, что случайный вектор  $X = (X^{(1)}, \dots, X^{(k)})'$  примет фиксированное значение  $x = (x^{(1)}, \dots, x^{(k)})'$  задается выражением

$$P_\lambda(X^{(1)} = x^{(1)}, \dots, X^{(k)} = x^{(k)}) = e^{-\sum_{i=1}^k \lambda^{(i)}} \prod_{i=1}^k \frac{(\lambda^{(i)})^{x^{(i)}}}{x^{(i)}!}. \quad (3)$$

Здесь  $\lambda = (\lambda^{(1)}, \lambda^{(2)}, \dots, \lambda^{(k)})'$  - параметр многомерного распределения Пуассона;  $\lambda^{(i)}$  - действительные положительные числа;  $x^{(i)}$  - целые неотрицательные числа,  $i = \overline{1, k}$ .

Математические ожидания и дисперсии для распределения (3) находятся аналогично одномерному распределению по следующим формулам:

$$M_{\lambda^{(i)}}(X) = D_{\lambda^{(i)}}(X) = \lambda^{(i)}, \quad i = \overline{1, k}.$$

Асимптотическое поведение многомерного распределения Пуассона (3) было изучено в работах [60], [64], [65]. Известно, что при  $\lambda^{(i)} \rightarrow \infty$ ,  $x^{(i)} = \lambda^{(i)} + O((\lambda^{(i)})^{1/2})$ ,  $i = \overline{1, k}$  и любом натуральном  $\nu$  для вероятностей (3) имеет место следующее разложение

$$P_\lambda(X^{(1)} = x^{(1)}, \dots, X^{(k)} = x^{(k)}) = \frac{1}{(2\pi)^{k/2} \left(\prod_{i=1}^k \lambda^{(i)}\right)^{1/2}} \cdot e^{-1/2 \sum_{i=1}^k y_i^2} \times \\ \times \exp \left\{ \sum_{s=1}^{\nu-1} (-1)^{s-1} \sum_{j=0}^{[(s+1)/2]} \binom{s-j+2}{j} \frac{B_j}{(s-j+1)(s-j+2)} \sum_{i=1}^k \frac{y_i^{s-2j+2}}{(\lambda^{(i)})^{s/2}} + \right. \\ \left. + O\left(\max_{i=\overline{1, k}} (\lambda^{(i)})^{-\nu/2}\right) \right\}, \quad (4)$$

где  $y_i = \frac{x^{(i)} - \lambda^{(i)}}{\sqrt{\lambda^{(i)}}}$ ,  $i = \overline{1, k}$ . Главный член в разложении (4) является  $k$ -мерным, нормальным рас-

пределением с вектором математических ожиданий  $\mu = (\mu_1, \mu_2, \dots, \mu_k)$  и матрицей ковариации  $\Sigma = \|\sigma_{i,j}\|$ ,  $i, j = \overline{1, k}$ .

$$\mu_i = \lambda^{(i)}, \sigma_{i,j} = \begin{cases} \lambda^{(i)}, & i = j, \\ 0, & i \neq j. \end{cases}$$

В данной статье исследован статистический подход к анализу дискретных данных, имеющих многомерное распределение Пуассона (3) с помощью методов статистической групповой классификации. Задачи групповой и поточечной классификации решались ранее в основном для совокупностей, имеющих непрерывные распределения. Реальные задачи классификации, как правило, сводятся к вероятностной модели, основанной на предположении о принадлежности рассматриваемой совокупности данных к известным и наиболее часто встречающимся параметрическим семействам распределений, к таким как многомерное нормальное распределение, многомерное распределение Стьюдента, распределение Уишарта, экспоненциальное распределение.

В статье разработаны методы групповой и поточечной классификации, позволяющие исследовать вероятностные модели дискретных распределений. Построены оптимальные решающие правила групповой классификации для многомерного распределения Пуассона. В качестве частных случаев получены решающие правила поточечной классификации.

Построим оптимальные решающие правила групповой классификации для многомерного распределения Пуассона. Так как случай  $M > 2$  классов сводится к последовательному решению задач классификации двух классов, то далее будут приведены правила групповой классификации полностью описанных двух классов  $\pi_1$  и  $\pi_2$ , подробно они изложены в работе [5].

При отсутствии какой-либо априорной информации о вероятностях заданных распределений  $P(\pi_{00} | \pi_s)$  ( $s = 1, 2$ ) оптимальное решающее правило групповой классификации, основанное на отношении функций правдоподобия, будет иметь вид

$$\pi_{00} \subset \pi_1, \text{ если } \frac{L(\pi_{00} | \pi_1)}{L(\pi_{00} | \pi_2)} \geq V, \quad (5)$$

где  $V = \frac{q_2 C(1/2)}{q_1 C(2/1)}$  - заданный порог.

Если же априори известно, что условные распределения вероятностей  $P(\pi_{00} | \lambda_s)$  зависят от некоторого параметра  $\lambda_s$  ( $s=1, 2$ ), то оптимальное решающее правило групповой классификации строится как отношение условных распределений вероятностей достаточной статистики  $t$  вида

$$\pi_{00} \subset \pi_1, \text{ если } \frac{P(t | \lambda_1)}{P(t | \lambda_2)} \geq V. \quad (6)$$

Для многомерного распределения Пуассона (3) условная функция правдоподобия задается соотношением

$$L(\pi_{00} | \pi_s) = e^{-n_0 \sum_{i=1}^k \lambda_s^{(i)}} \cdot \prod_{i=1}^k \frac{(\lambda_s^{(i)})^{\sum_{j=1}^{n_0} x_{0j}^{(i)}}}{\prod_{j=1}^{n_0} x_{0j}^{(i)}!}, \quad (7)$$

а условные распределения вероятностей достаточной статистики  $U_0 = (U_0^{(1)}, U_0^{(2)}, \dots, U_0^{(k)})'$  параметра  $\lambda_s = (\lambda_s^{(1)}, \lambda_s^{(2)}, \dots, \lambda_s^{(k)})'$ , где  $U_0^{(i)} = \sum_{j=1}^{n_0} x_{0j}^{(i)}$ ,  $i = \overline{1, k}$  могут быть найдены по формуле

$$P(U_0 | \lambda_s) = e^{-n_0 \sum_{i=1}^k \lambda_s^{(i)}} \cdot \prod_{i=1}^k \frac{(\lambda_s^{(i)})^{U_0^{(i)}}}{U_0^{(i)}!}. \quad (8)$$

Пусть объекты в совокупностях  $\pi_s$  ( $s=1, 2$ ) имеют многомерное распределение Пуассона с вероятностями (3). При отнесении выборки  $\pi_{00}$  к одной из двух совокупностей  $\pi_1$ ,  $\pi_2$  оптимальное решающее правило групповой классификации (5), построенное на основе отношения функций правдоподобия, запишется следующим образом

$$\pi_{00} \subset \pi_1, \text{ если } e^{n_0 \sum_{i=1}^k (\lambda_2^{(i)} - \lambda_1^{(i)})} \cdot \prod_{i=1}^k \left( \frac{\lambda_1^{(i)}}{\lambda_2^{(i)}} \right)^{U_0^{(i)}} \geq V. \quad (9)$$

Для многомерного распределения Пуассона использование оптимального решающего правила (8), построенного на отношении условных распределений вероятностей достаточных статистик приводит к тому же правилу (9).

Если ранее распределения данных внутри совокупностей  $\pi_s$  ( $s = \overline{1, M}$ ) предполагались известными, то далее будем считать, что распределения данных известны лишь частично, т.е. содержат неизвестные параметры. В этом случае совокупности задаются только конечными подмножествами своих представителей  $\pi_{s0} = (x_{s1}, x_{s2}, \dots, x_{sN_s})$ , называемыми обучающими выборками объемов  $N_s$  из совокупностей  $\pi_s$  ( $s = \overline{1, M}$ ).

Пусть объекты в совокупностях  $\pi_s$  распределены в соответствии с вероятностями  $P(x | \lambda_s)$ , которые зависят от неизвестного параметра  $\lambda_s$ , а достаточная статистика  $t = U_0$ . Как и ранее, для простоты рассматривается случай, когда имеются только две совокупности  $\pi_1$  и  $\pi_2$ , заданные своими обучающими выборками  $\pi_{10}$  и  $\pi_{20}$ , соответственно, и выборка  $\pi_{00}$ , которую нужно отнести к одной из них.

В классической задаче распознавания образов по одному объекту (поточечной классификации) [5][6] решающие правила строились только по обучающим выборкам  $\pi_{s0}$  ( $s=1,2$ ). Это означало, что структурно они включают только отношения независимых величин. Позднее, в работах [7], [8] был введен принципиально новый подход к решению задач статистической групповой классификации. Классифицируемая выборка  $\pi_{00}$  стала использоваться вместе с обучающими выборками  $\pi_{s0}$  для построения самих статистических решающих функций. При таком подходе возникает другая структура решающих правил, заключающаяся в том, что эти правила основаны на отношениях зависимых случайных величин.

Найдем оценки максимального правдоподобия  $\check{L}(\pi_{00} | \lambda_s)$ ,  $\check{P}(t | \lambda_s)$  и построим статистические решающие правила на их основе для многомерного распределения Пуассона (3), где неизвестный параметр  $\lambda_s$ , достаточная статистика  $t = U_0$ .

Известно [9], [10], что оценкой максимального правдоподобия для неизвестного параметра  $\lambda^{(i)}$  многомерного распределения Пуассона (3) является:  $\lambda^{(i)} = \frac{x^{(i)}}{N}$ , где  $N$  - объем выборки,  $i = \overline{1, k}$ . Тогда по объединенной выборке  $\pi_{s0} \cup \pi_{00}$  эта оценка запишется

$$\check{\lambda}_s^{(i)} = \frac{\sum_{j=1}^{N_s} x_{sj}^{(i)} + \sum_{j=1}^{n_0} x_{0j}^{(i)}}{N_s + n_0} = \frac{U^{(i)}_{N_s+n_0}}{N_s + n_0}, \quad (i = \overline{1, k}).$$

Подставив  $\lambda_s^{(i)}$  ( $s=1,2; i = \overline{1, k}$ ) в выражения (7), (8) получим оценки максимального правдоподобия

$$\check{L}(\pi_{00} | \lambda_s) = e^{-\frac{n_0}{N_s+n_0} \sum_{i=1}^k U^{(i)}_{N_s+n_0}} \prod_{i=1}^k \frac{1}{\prod_{j=1}^{n_0} x_{0j}^{(i)}!} \cdot \left( \frac{U^{(i)}_{N_s+n_0}}{N_s + n_0} \right)^{U_0^{(i)}}. \quad (10)$$

$$\check{P}(U_0 | \lambda_s) = e^{-\frac{n_0}{N_s+n_0} \sum_{i=1}^k U^{(i)}_{N_s+n_0}} \prod_{i=1}^k \frac{1}{U_0^{(i)}!} \cdot \left( \frac{U^{(i)}_{N_s+n_0}}{N_s + n_0} \right)^{U_0^{(i)}}. \quad (11)$$

Пусть объекты в совокупностях  $\pi_s$  имеют многомерное распределение Пуассона (3) с неизвестным параметром  $\lambda_s$  ( $s=1,2$ ). При отнесении выборки  $\pi_{00}$  к одной из совокупностей  $\pi_1, \pi_2$  статистическое решающее правило групповой классификации, основанное на отношении оценок максимального правдоподобия, построенных по объединенной выборке  $\pi_{s0} \cup \pi_{00}$  ( $s=1,2$ ) будет иметь вид

$\pi_{00} \subset \pi_1$ , если

$$\frac{e^{-\frac{n_0}{N_1+n_0} \sum_{i=1}^k U^{(i)}_{N_1+n_0}} \prod_{i=1}^k \left( \frac{(N_2 + n_0) U^{(i)}_{N_1+n_0}}{(N_1 + n_0) U^{(i)}_{N_2+n_0}} \right)^{U_0^{(i)}}}{e^{-\frac{n_0}{N_2+n_0} \sum_{i=1}^k U^{(i)}_{N_2+n_0}} \prod_{i=1}^k \left( \frac{(N_1 + n_0) U^{(i)}_{N_2+n_0}}{(N_2 + n_0) U^{(i)}_{N_1+n_0}} \right)^{U_0^{(i)}}} \geq V. \quad (12)$$

Статистическое решающее правило (12), основанное на отношении оценок максимального правдоподобия, построенных по обучающей выборке  $\pi_{s0}$  ( $s=1,2$ ) примет вид

$$\pi_{00} \subset \pi_1, \text{ если } \frac{e^{-\frac{n_0}{N_1} \sum_{i=1}^k U^{(i)}_{N_1}}}{e^{-\frac{n_0}{N_2} \sum_{i=1}^k U^{(i)}_{N_2}}} \prod_{i=1}^k \left( \frac{N_2 U^{(i)}_{N_1}}{N_1 U^{(i)}_{N_2}} \right)^{U_0^{(i)}} \geq V. \quad (13)$$

При  $n_0 = 1$  из правил (12), (13) могут быть получены статистические решающие правила поточечной классификации многомерного распределения Пуассона (3).

Рассмотрим способы нахождения несмещенных оценок  $P(\pi_{00} | \lambda_s)$ ,  $P(U_0 | \lambda_s)$  и построения статистических решающих правил на их основе в случае многомерного распределения Пуассона (3) при неизвестном значении параметра  $\lambda_s$  ( $s=1,2$ ).

Найдем несмещенную оценку условной функции правдоподобия  $L(\pi_{00} | \lambda_s)$  по объединенной выборке

$$\begin{aligned} P(\pi_{00} | \lambda_s) &= \frac{P(\pi_{00}, \pi_{s0} + \pi_{00} | \lambda_s)}{P(\pi_{s0} + \pi_{00} | \lambda_s)} = \frac{P(\pi_{00} | \lambda_s) \cdot P(\pi_{s0} | \lambda_s)}{P(\pi_{s0} + \pi_{00} | \lambda_s)} = \\ &= \frac{N_s^{\sum_{i=1}^k U^{(i)}_{N_s}}}{(N_s + n_0)^{\sum_{i=1}^k U^{(i)}_{N_s+n_0}} \prod_{j=1}^{n_0} \prod_{i=1}^k x_{0j}^{(i)}!} \cdot \prod_{i=1}^k \frac{U^{(i)}_{N_s+n_0}!}{U^{(i)}_{N_s}!}, \quad (14) \end{aligned}$$

где  $P(\pi_{00} | \lambda_s)$ ,  $P(\pi_{s0} | \lambda_s)$ ,  $P(\pi_{s0} + \pi_{00} | \lambda_s)$  находятся путем вычисления функций правдоподобия по выборкам  $\pi_{00}$ ,  $\pi_{s0}$ ,  $\pi_{s0} \cup \pi_{00}$  соответственно.

Аналогично находится несмещенная оценка для вероятности условного распределения достаточной статистики  $P(U_0 | \lambda_s)$  на основе объединенной выборки  $\pi_{s0} \cup \pi_{00}$  ( $s=1,2$ ), которая имеет вид

$$\begin{aligned} P(U_0 | \lambda_s) &= \frac{P(U_0, U_{N_s+n_0} | \lambda_s)}{P(U_{N_s+n_0} | \lambda_s)} = \frac{P(U_0 | \lambda_s) \cdot P(U_{N_s} | \lambda_s)}{P(U_{N_s+n_0} | \lambda_s)} = \\ &= \frac{n_0^{\sum_{i=1}^k U_0^{(i)}} N_s^{\sum_{i=1}^k U^{(i)}_{N_s}}}{(N_s + n_0)^{\sum_{i=1}^k U^{(i)}_{N_s+n_0}} \prod_{i=1}^k U_0^{(i)}!} \cdot \prod_{i=1}^k \frac{U^{(i)}_{N_s+n_0}!}{U^{(i)}_{N_s}!}. \quad (15) \end{aligned}$$

где  $P(U_0 | \lambda_s)$ ,  $P(U_{N_s} | \lambda_s)$ ,  $P(U_{N_s+n_0} | \lambda_s)$  находятся по формуле (8).

На основе полученных несмещенных оценок строятся статистические решающие правила групповой и поточечной классификации многомерного распределения Пуассона при неизвестном значении параметра  $\lambda_s$  ( $s=1,2$ ).

Пусть объекты в совокупностях  $\pi_s$  имеют многомерное распределение Пуассона (3) с неизвестным параметром  $\lambda_s$  ( $s=1,2$ ). При отнесении выборки  $\pi_{00}$  к какой-либо одной из совокупностей  $\pi_1, \pi_2$  статистическое решающее правило групповой классификации, основанное на отношении несмещенных оценок, построенных по объединенной выборке  $\pi_{s0} \cup \pi_{00}$  ( $s=1,2$ ) будет иметь вид

$$\pi_{00} \subset \pi_1, \text{ если } \frac{N_1^{\sum_{i=1}^k U^{(i)}_{N_1}}}{N_2^{\sum_{i=1}^k U^{(i)}_{N_2}}} \cdot \frac{(N_2 + n_0)^{\sum_{i=1}^k U^{(i)}_{N_2+n_0}}}{(N_1 + n_0)^{\sum_{i=1}^k U^{(i)}_{N_2+n_0}}} \cdot \prod_{i=1}^k \frac{U^{(i)}_{N_2}! U^{(i)}_{N_1+n_0}!}{U^{(i)}_{N_1}! U^{(i)}_{N_2+n_0}!} \geq V. \quad (16)$$

При  $n_0 = 1$  из правила (16) может быть получено статистическое решающее правило поточечной классификации многомерного распределения Пуассона (3).

### Литература:

1. Беляев Ю.К., Лумельский Я.П. Многомерные пуассоновские блуждания// Статистические методы: Межвуз. сб. научн. тр./ Перм. ун-т. Пермь. 1978. С.12 - 17.
2. Ившин В.В., Лумельский Я.П. Статистические задачи оценивания в модели "нагрузка-прочность"// Изд-во Перм. ун-т. Пермь. 1995. 128с.
3. Лумельский Я.П. Статистические оценки результатов контроля качества. М.: Изд-во стандартов. 1979. 200с.

4. Лумельский Я.П., Шеховцова М.Г. Пуассоновские блуждания и оценка надежности// Статист. методы оценивания и проверки гипотез: Межвуз. сб. науч. тр./ Перм. ун-т. Пермь. 1978. С.88 - 100.
5. Каменева С.В. О некоторых задачах проверки гипотез и групповой классификации. Случай дискретных распределений. LAP Lambert. 2016.104 с.
6. Айвазян С.А., Бежаева З.И., Староверов О.В. Классификация многомерных наблюдений. М.: Статистика. 1974. 240 с.
7. Абусев Р.А. Групповая классификация. Решающие правила и их характеристики. Изд-во Пермского университета. Пермь. 1992. 220 с.
8. Абусев Р.А., Лумельский Я.П. Статистическая групповая классификация// Изд-во Перм. ун-та. Пермь. 1987. 92с.
9. Абусев Р.А. Многомерные пуассоновские блуждания и оценивание распределений достаточных статистик// Тезисы докл. на VII Вильнюсской конф. по теор. вероятн. и матем. статистике. Вильнюс. 1998. С.17.
10. Бабушкина Е.В., Каменева С.В., Абусев Р.А. Оценивание линейных стохастических неравенств в задачах надежности// Материалы межвузовского научно-технического семинара “Проблемы и перспективы рационального управления эксплуатацией вооружения”// Изд-во ПВКИУ. Пермь. 2002. Вып.9. С.22-29.