

Л.А. ЗОЛОТУХИНА

## АСИМПТОТИЧЕСКОЕ РАСПРЕДЕЛЕНИЕ ЧИСЛА СОВПАДЕНИЙ ДВУМЕРНОЙ ВЫБОРКИ ПРИ НАТУРАЛЬНОМ СОВМЕЩЕНИИ

### 1. Введение

Классическая задача о совпадениях сформулирована Монмортом в 1708 г. Пусть мы имеем, например, две колоды карт. Перетасуем колоды каждую в отдельности, а затем разложим на столе одну под другой. Если сверху и снизу оказалась одна и та же карта, то будем говорить о совпадении. Известно, что среднее число совпадений при таком сопоставлении при любом числе карт в колоде равно 1. Если же будем увеличивать число карт в колоде, распределение числа совпадений будет стремиться к распределению Пуассона с параметром 1.

В работах [1]–[3] было рассмотрено следующее обобщение этой задачи. Пусть выборка  $(u_i, t_i)$  ( $i = 1, \dots, n$ ) объема  $n$  извлечена из двумерной генеральной совокупности с плотностью распределения  $f(x, y) > 0$  при  $a < x < b$ ,  $c < y < d$ . Возможно  $a, c$  равны  $-\infty$ , а  $b, d$  равны  $+\infty$ . Но компоненты каждого выборочного вектора  $(u_i, t_i)$  наблюдаются отдельно, так что имеем два набора наблюдений:

$\vec{t} = (t_1, \dots, t_n)$  — наблюдения первой компоненты,

$\vec{u} = (u_1, \dots, u_n)$  — наблюдения второй компоненты.

Затем элементы каждой из выборок располагаются в случайном порядке (любая перестановка  $(t_1, \dots, t_n)$  и  $(u_1, \dots, u_n)$  является равновероятной). Необходимо найти такой способ соединения элементов выборок  $\vec{t}$  и  $\vec{u}$  в пары, чтобы наилучшим образом репродуцировать пары исходной выборки. В [1] было предложено несколько критериев оптимальности, в частности, а) максимизация вероятности репродукции пар и б) максимизация среднего числа совпадений. Способ соединения в пары, удовлетворяющий критерию б), был назван “оптимальным” в отличие от удовлетворяющего критерию а) “максимального правдоподобия” (ML). Способ, при котором в пары объединяются соответствующие элементы вариационных рядов, будем называть натуральным совмещением.

В совокупности в [1]–[3] были получены следующие результаты. Пусть плотность распределения генеральной совокупности  $f(x, y) > 0$ ,  $x \in R$ ,  $y \in R$ , и обладает монотонным отношением правдоподобия

$$f(x_1, y_1)f(x_2, y_2) \geq f(x_1, y_2)f(x_2, y_1) \text{ для } x_1 < x_2; y_1 < y_2.$$

Тогда а) ML-правило есть натуральное совмещение; б) оптимальное правило предполагает объединение в пары наибольших и наименьших элементов  $\vec{t}$  и  $\vec{u}$ ; в) при натуральном совмещении среднее число совпадений не меньше 1, т. е. натуральное совмещение всегда не хуже случайного объединения в пары.

Все эти выводы были сделаны авторами для любых объемов выборки  $n$ . Позже в [4], [5] были получены интегральные представления математического ожидания и дисперсии числа совпадений, а также вычислена асимптотика при  $n \rightarrow +\infty$  среднего числа совпадений при натуральном совмещении.

Целью данной статьи является получение интегрального представления всех моментов числа совпадений (п.2), а также доказательство того факта, что асимптотическое распределение числа

совпадений — распределение Пуассона с параметром  $\lambda = \int_a^b \frac{f(x, y^*(x))}{f_2(y^*(x))} dx < \infty$ , где  $f_2(y) = \int_a^b f(x, y) dx > 0$  — маргинальная плотность распределения второй компоненты,

$$F_1(x) = \int_a^x \int_c^d f(x, y) dx dy, \quad F_2(x) = \int_a^b \int_c^y f(x, y) dx dy$$

— маргинальные функции распределения  $u_i$  и  $t_i$  соответственно, а  $y^*(x) = F_2^{-1}(F_1(x))$ .

Если же  $\lambda = \infty$ , то распределение числа совпадений асимптотически нормально, точнее

$$P\left(\frac{N - MN}{\sqrt{DN}} < x\right) \rightarrow \phi(x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x \exp\left(-\frac{u^2}{2}\right) du.$$

Кроме того, п. 5 содержит доказательство следующего утверждения: для любого  $n$  число совпадений распределено по рандомизированному биномиальному закону.

## 2. Интегральные представления моментов

В дальнейшем для определенности положим  $f(x, y) > 0$ ,  $x \in R$ ,  $y \in R$ . Итак, пусть из двумерной генеральной совокупности с плотностью  $f(x, y)$  извлечена выборка  $((t_1, \dots, t_n), (u_1, \dots, u_n))$  отдельно по компонентам. Пусть, кроме того,  $(x_1, x_2, \dots, x_n)$  — упорядоченные  $(t_1, t_2, \dots, t_n)$ , а  $(y_1, y_2, \dots, y_n)$  — упорядоченные  $(u_1, u_2, \dots, u_n)$ . Будем объединять в пары  $x_i$  с  $y_i$  — в этом состоит натуральное совмещение.

Случайные величины  $\chi_i$  введем следующим образом:  $\chi_i = 1$ , если среди образовавшихся пар присутствует пара  $(t_i, u_i)$ , и  $\chi_i = 0$  в противном случае.

Пусть  $N$  — число совпадений. Очевидно,  $N = \sum_{i=1}^n \chi_i$  и  $\chi_i$  зависимы симметрично. Тогда

$$MN^k = M\left(\sum_{i=1}^n \chi_i\right)^k = M \sum_{(k_1, \dots, k_n)} \frac{\chi_1^{k_1} \chi_2^{k_2} \dots \chi_n^{k_n}}{k_1! k_2! \dots k_n!} k! = \sum_{j=1}^k \frac{c_{jk} n!}{(n-j)!} M\left(\prod_{m=1}^j \chi_m\right), \quad (2.1)$$

т. к.  $\chi_i^k = \chi_i$  для любых целых  $i$  и  $k$ ,  $M \chi_{i_1} \chi_{i_2} \dots \chi_{i_j} = M \chi_1 \chi_2 \dots \chi_j$  в силу симметричной зависимости  $\chi_i$ . Необходимо вычислить моменты вида  $M(\chi_1 \dots \chi_k)$ .

Нетрудно видеть, что  $M(\chi_1 \dots \chi_k) = P(\chi_1 = 1, \dots, \chi_k = 1)$ . Зафиксируем первые  $k$  пар  $(t_1, u_1), \dots, (t_k, u_k)$ . Пусть все эти пары истинны при натуральном совмещении,  $(x_1, \dots, x_k)$  упорядоченны по возрастанию  $(t_1, \dots, t_k)$ , а  $(y_1, \dots, y_k)$  упорядоченны  $(u_1, \dots, u_k)$ . Тогда множества пар  $\{(x_1, y_1), \dots, (x_k, y_k)\}$  и  $\{(t_1, u_1), \dots, (t_k, u_k)\}$  совпадают. Посмотрим, как могут распределиться остальные  $n - k$  пар. Ясно, что, сложив вероятности возможных исходов, будем иметь искомую вероятность.

Чтобы облегчить описание процедуры подсчета, введем несколько понятий.

Пусть пары  $(x_i, y_i)$ ,  $i \in 1, \dots, k$ , истинны при натуральном совмещении. Точки с координатами  $(x_i, y_i)$ ,  $i \in 1, \dots, k$ , назовем узлами. Каждый узел прямыми  $y = y_i$  и  $x = x_i$  делит плоскость на четыре части. Очевидно, для каждого узла число остальных пар, попавших в левую верхнюю четверть, и в нижнюю правую должны совпадать. Это число для  $i$ -й истинной пары будем называть  $i$ -м ящиком и обозначать  $S_i$ . Далее, левую верхнюю четверть назовем для удобства  $i$ -м верхним ящиком, правую нижнюю —  $i$ -м нижним ящиком.

Каждой клетке сопоставим вероятность попадания в нее и число пар, в нее попавших. Клетка — прямоугольник, ограниченный прямыми  $y = y_i$ ,  $y = y_{i+1}$ ,  $x = x_i$ ,  $x = x_{i+1}$ , где  $x_0 = y_0 = -\infty$ ,  $x_{k+1} = y_{k+1} = +\infty$ . Нумерацию строк будем вести снизу вверх, столбцов — слева направо.

Для каждого ящика число пар, попавших в клетки, прилегающие к главной диагонали (соединяющей левую нижнюю клетку с правой верхней), будем вычислять как  $S_i$  минус число пар, попавших в остальные клетки ящика. Эти клетки назовем соответственно результирующими верхнего (нижнего) ящика. Клетки ящика, не прилегающие к главной диагонали, назовем

элементами ящика. По аналогии с понятием ящика будем числу пар, попавших в клетку, давать то же название, что и самой клетке.

Итак, пусть  $k_{ij}$  — элемент ящика. Символом  $\sum_i^{(1)}$  будем обозначать суммы элементов  $i$ -го верхнего ящика, символом  $\sum_i^{(2)}$  —  $i$ -го нижнего. Пусть, наконец,  $p_{ij}$  — вероятность попадания в клетку  $(i, j)$ ,  $g = 1 - \sum_{i \neq j} p_{ij}$ , а  $\sum^*$  — число пар, не попавших на главную диагональ. Искомая вероятность равна

$$\sum_{k_{ij}, S_i} \frac{(n-k)! \prod_{|i-j| \geq 2} p_{ij}^{k_{ij}} \prod_i \left( p_{i, i+1}^{S_i - \sum_i^{(2)}} \right) \left( p_{i+1, i}^{S_i - \sum_i^{(1)}} \right) (g^{n-k - \sum^*})}{\prod_{|i-j| \geq 2} (k_{ij})! \prod_i (S_i - \sum_i^{(1)})! (S_i - \sum_i^{(2)})! (n-k - \sum^*)!},$$

где суммирование проводится при неотрицательности всех чисел, стоящих в знаменателе под знаком факториала;  $k_{ij}$  исчезли при суммировании (см. [4]).

Легко видеть, что каждый член суммы равен

$$\frac{1}{(2\pi i)^{k^2+k}} \int_{\Gamma \subset C^{k^2+k}} \frac{\left( g + \sum_{i \neq j} p_{ij} u_{ij} \right)^{n-k} du}{\prod_{i \neq j} u_{ij} \prod_{|i-j| \geq 2} u_{ij}^{k_{ij}} \prod_i \left( u_{i, i+1}^{S_i - \sum_i^{(1)}} u_{i+1, i}^{S_i - \sum_i^{(2)}} \right)},$$

где  $\Gamma$  — декартово произведение  $k^2 + k$  замкнутых контуров на комплексных плоскостях, содержащих точку  $(0, 0)$  внутри себя. Если какая-то из степеней в знаменателе будет больше  $n - k$ , то соответствующий интеграл обратится в нуль; поэтому суммирование по всем переменным можно вести до бесконечности. Теперь все суммы по  $k_{ij}$  — бесконечные геометрические прогрессии. Выберем контур интегрирования так, чтобы эти прогрессии бесконечно убывали.

Обозначив искомую вероятность при фиксированных  $(x_1, y_1), (x_2, y_2), \dots, (x_k, y_k)$  через  $P$ , будем иметь

$$P = \frac{1}{(2\pi i)^{k^2+k}} \sum_{S_i} \int_{\Gamma \subset C^{k^2+k}} \frac{\left( g + \sum_{i \neq j} p_{ij} u_{ij} \right)^{n-k}}{\prod_i (u_{i, i+1} u_{i+1, i})^{S_i} \prod_{i \neq j} u_{ij} \prod_{i-j > 1} \left( 1 - \prod_{m=j}^{i-1} u_{m+1, m} / u_{ij} \right)} \times \\ \times \frac{du}{\prod_{i-j < -1} \left( 1 - \prod_{m=i}^{j-1} u_{m, m+1} / u_{ij} \right)}.$$

Проинтегрируем по  $u_{ij}$ , где  $|i - j| > 1$ , затем просуммируем по ящикам и проинтегрируем по  $u_{i+1, i}$ , т. е. по соответствующим результирующим верхним ящикам. В итоге получим

$$P = \frac{1}{(2\pi i)^k} \int_{\Gamma \subset C^k} f(u) du,$$

где

$$f(u) = \frac{\left( g + \sum_{i < j} \left( p_{ij} \prod_{m=i}^{j-1} u_{m, m+1} + p_{ji} \prod_{m=i}^{j-1} u_{m+1, m}^{-1} \right) \right)^{n-k}}{\prod_{i=1}^k u_{i, j+1}}.$$

Осталось осреднить  $P$  по возможным значениям  $(x_1, y_1), (x_2, y_2), \dots, (x_k, y_k)$  и учесть, что всего существует  $k!$  перестановок  $(x_1, y_1), (x_2, y_2), \dots, (x_k, y_k)$ . Тогда для момента  $M(\chi_1 \dots \chi_k)$  имеем

интегральное представление

$$\frac{k!}{(2\pi i)^k} \int_{x_1 < \dots < x_k} \dots \int_{y_1 < \dots < y_k} \dots \int_{\Gamma \subset C^k} f(u) du \times \prod_{i=1}^k (f(x_i, y_i) dx_i dy_i). \quad (2.2)$$

Для нахождения  $MN^k$  осталось применить (2.1).

### 3. Асимптотика $MN^k$ при $n \rightarrow \infty$

Как и в предыдущем пункте, займемся сначала моментами вида  $M(\chi_1 \dots \chi_k)$ , а затем воспользуемся формулой (2.1).

Для нахождения асимптотики  $M(\chi_1 \dots \chi_k)$  применим метод перевала по переменным  $u_{m,m+1}$  и метод Лапласа по переменным  $y_i$ . Обозначим

$$H = H(u, x, y) = g + \sum_{i < j} \left( p_{ij} \prod_{m=i}^{j-1} u_{m,m+1} + p_{ji} \prod_{m=i}^{j-1} u_{m,m+1}^{-1} \right),$$

где

$$g = 1 - \sum_{i < j} (p_{ij} + p_{ji}),$$

$$u = (u_{12}, u_{23}, \dots, u_{k,k+1}), \quad x = (x_1, \dots, x_k), \quad y = (y_1, \dots, y_k),$$

причем  $y_1 < y_2 < \dots < y_k$ ,  $x_1 < x_2 < \dots < x_k$ .

Для нахождения асимптотики интеграла по замкнутому контуру  $\Gamma$  необходимо найти точку, в которой достигается минимакс

$$\min_{\Gamma \in G} \max_{u \in \Gamma} \operatorname{Re} H(u, x, y), \quad (3.1)$$

где  $G$  — множество всех контуров, сохраняющих значение интеграла. В качестве контуров  $G$  будем рассматривать окружности  $u_{m,m+1} = r_m \exp(i\psi_m)$ ,  $m = 1, \dots, k$ . Тогда для нахождения асимптотики интеграла (2.2) нужно найти точку  $(y^*, u^*)$ , в которой достигается минимакс

$$L(x) = \max_y \min_{r_m} \max_{\psi_m} \operatorname{Re} H(u, x, y). \quad (3.2)$$

**Теорема 1.** Минимакс в (3.2)  $L(x) \equiv 1 \forall x$  и достигается при

$$u_{m,m+1}^* = 1, \quad m = 1, \dots, k; \quad y_i^*(x_i) = F_2^{-1}(F_1(x_i)), \quad i = 1, \dots, k,$$

где

$$F_1(x) = \int_{-\infty}^x \int_{-\infty}^{+\infty} f(x, y) dx dy, \quad F_2(y) = \int_{-\infty}^{+\infty} \int_{-\infty}^y f(x, y) dx dy.$$

**Доказательство.** Найдем сначала  $\max_{\psi_m} \operatorname{Re} H(u, x, y)$ . Имеем

$$\begin{aligned} \operatorname{Re} H(u, x, y) &= \operatorname{Re} \left( g + \sum_{i < j} (p_{ij} r_i \dots r_{j-1} \exp(i(\psi_1 + \dots + \psi_{j-1}))) + \right. \\ &\quad \left. + p_{ji} r_i^{-1} \dots r_{j-1}^{-1} \exp(-i(\psi_1 + \dots + \psi_{j-1})) \right) = \\ &= g + \sum_{i < j} (p_{ij} r_i \dots r_{j-1} \cos(\psi_1 + \dots + \psi_{j-1}) + p_{ji} r_i^{-1} \dots r_{j-1}^{-1} \cos(\psi_1 + \dots + \psi_{j-1})), \end{aligned}$$

и максимум достигается при  $\psi_1 = \psi_2 = \dots = \psi_k = 0$ .

В точке минимакса  $\frac{\partial H}{\partial y_1} = 0$ , поэтому

$$\begin{aligned} \frac{\partial H}{\partial y_1} &= -(1 - r_1) \int_{-\infty}^{x_1} f(x, y_1) dx + \left(1 - \frac{1}{r_1}\right) \int_{x_1}^{x_2} f(x, y_1) dx + \\ &\quad + \left(1 - \frac{1}{r_1 r_2}\right) \int_{x_2}^{x_3} f(x, y_1) dx + \dots + \left(1 - \frac{1}{r_1 \dots r_{k-1}}\right) \int_{x_k}^{+\infty} f(x, y_1) dx - \\ &- \left(1 - \frac{1}{r_2}\right) \int_{x_2}^{x_3} f(x, y_1) dx - \left(1 - \frac{1}{r_2 r_3}\right) \int_{x_3}^{x_4} f(x, y_1) dx - \dots - \left(1 - \frac{1}{r_2 \dots r_{k-1}}\right) \int_{x_k}^{+\infty} f(x, y_1) dx = \\ &= (r_1 - 1) \left( \int_{-\infty}^{x_1} f(x, y_1) dx + \frac{1}{r_1} \int_{x_1}^{x_2} f(x, y_1) dx + \frac{1}{r_1 r_2} \int_{x_2}^{x_3} f(x, y_1) dx + \dots + \right. \\ &\quad \left. + \frac{1}{r_1 \dots r_{k-1}} \int_{x_k}^{+\infty} f(x, y_1) dx \right) = 0. \end{aligned}$$

Отсюда  $r_1 = 1$ . Аналогично, из условия  $\frac{\partial H}{\partial y_i} = 0$  следует  $r_i = 1$ ,  $i = 2, \dots, k$ .

Итак, минимакс достигается при  $u_{m, m+1}^* = 1$ ,  $m = 1, \dots, k$ , поэтому  $\frac{\partial H}{\partial u_{m, m+1}} \Big|_{u^*=1} = 0$ . Значит,

$$\frac{\partial H}{\partial u_{m, m+1}} \Big|_{u^*=1} = \sum_{i < j} (p_{ij} - p_{ji}) = \int_{-\infty}^{x_m} \int_{y_m}^{+\infty} f(x, y) dx dy - \int_{x_m}^{+\infty} \int_{-\infty}^{y_m} f(x, y) dx dy = 0.$$

Поскольку  $F_1(x)$  и  $F_2(y)$  — возрастающие непрерывные функции, то  $\forall x_m \in R \exists z \in (0, 1) : F_1(x_m) = z$ , а для  $z \exists y_m : F_2(y_m) = z$ . Следовательно,  $F_1(x_m) = F_2(y_m)$ , а  $L(x) = 1$ .  $\square$

Теперь можно получить асимптотику интеграла (2.2) (см. [6], с. 418, предложение 4.1, с. 122, теорема 4.1) в виде

$$k! \int \dots \int_{x_1 < \dots < x_k} \frac{\prod_i f(x_i, y_i^*) dx_i}{\sqrt{\det H(z, x, y)''_{zz} \Big|_{z=1, y=y^*} \det H(r^*, x, y)''_{xy} \Big|_{r^*=1, y=y^*}}}, \quad (3.3)$$

где  $r^*(x, y)$  — радиус перевального контура, а  $y^* : F_1(x_m) = F_2(y_m^*) \forall m$ . Заметим, что в точке  $(r^* = 1, y = y^*)$   $p_{ij} = p_{ji}$  для любых  $i$  и  $j$ .

#### 4. Выражение для $DN$

Получим выражение  $DN = MN^2 - (MN)^2 = nM\chi_1 + n(n-1)M\chi_1\chi_2 - n^2(M\chi_1)^2$ . Найдем  $\lim_{n \rightarrow +\infty} n(n-1)M\chi_1\chi_2$ . В соответствии с (3.3) имеем

$$n^2 M \chi_1 \chi_2 \sim 2! \iint_{x_1 < x_2} \frac{f(x_1, y_1^*(x_1)) f(x_2, y_2^*(x_2)) dx_1 dx_2}{\sqrt{\det H(z, x, y)''_{zz} \Big|_{z=1, y=y^*} \det H(r^*, x, y)''_{xy} \Big|_{r^*=1, y=y^*}}}.$$

**Теорема 2.** *Имеет место равенство*

$$\sqrt{\det H(z, x, y)''_{zz} \Big|_{z=1, y=y^*} \det H(r^*, x, y)''_{xy} \Big|_{r^*=1, y=y^*}} = f_2(y_1^*) f_2(y_2^*) > 0. \quad (4.1)$$

**Доказательство.** Для  $k = 2$  имеем

$$H = g + p_{12} z_1 + p_{21} \frac{1}{z_1} + p_{23} z_2 + p_{32} \frac{1}{z_2} + p_{13} z_1 z_2 + p_{31} \frac{1}{z_1 z_2}$$

и

$$\det H(z, x, y)''_{zz} \Big|_{z=1, y=y^*} = 4(p_{12} p_{23} + p_{12} p_{13} + p_{23} p_{13}).$$

Для получения второго определителя найдем производные вида  $(r_i^*)'_{y_j}$  в точке  $(r^* = 1, y = y^*)$ . Так как  $r^*$  — радиус перевального контура, то  $H(r^*, x, y)'_{r_i^*} = 0$ , т. е.

$$p_{12} - \frac{p_{21}}{(r_1^*)^2} + p_{13}r_2^* - \frac{p_{31}}{(r_1^*)^2 r_2^*} = 0, \quad p_{23} - \frac{p_{32}}{(r_2^*)^2} + p_{13}r_2^* - \frac{p_{31}}{(r_2^*)^2 r_1^*} = 0.$$

Продифференцируем каждое из этих уравнений по  $y_1$

$$f_2(y_1) + 2r_{1y_1}^{*'}(p_{12} + p_{13}) + 2p_{13}r_{2y_1}^{*'} = 0; \quad 2r_{1y_1}^{*'}(p_{23} + p_{13}) + 2p_{13}r_{1y_1}^{*'} = 0.$$

Отсюда

$$r_{1y_1}^{*'} = -\frac{f_2(y_1)}{2} \frac{p_{23} + p_{13}}{p_{23}p_{13} + p_{12}p_{13} + p_{23} + p_{12}}; \quad r_{2y_1}^{*'} = \frac{f_2(y_1)}{2} \frac{p_{13}}{p_{23}p_{13} + p_{12}p_{13} + p_{23} + p_{12}}. \quad (4.2)$$

Аналогично,

$$r_{1y_2}^{*'} = \frac{f_2(y_2)}{2} \frac{p_{13}}{p_{23}p_{13} + p_{12}p_{13} + p_{23}p_{12}}, \quad r_{2y_2}^{*'} = -\frac{f_2(y_2)}{2} \frac{p_{13} + p_{12}}{p_{23}p_{13} + p_{12}p_{13} + p_{23}p_{12}}. \quad (4.2')$$

Введем обозначения  $r_{iy_j}^{*'} = a_{ij}$ ;  $(p_{12} - p_{21})'_{y_j} = b_{1j}$ ;  $(p_{13} - p_{31})'_{y_j} = b_{2j}$ ;  $(p_{23} - p_{32})'_{y_j} = b_{3j}$ . Учитывая, что  $b_{21} = -b_{31} = f_2(y_1) - b_{11}$ ;  $b_{22} = -b_{12} = f_2(y_2) - b_{32}$ , имеем

$$\begin{aligned} H''_{y_1 y_1} &= 2a_{11}b_{11} + 2a_{21}b_{31} + 2a_{11}^2 p_{12} + 2a_{21}^2 p_{23} + 2b_{21}(a_{11} + a_{21}) + 2p_{13}(a_{11} + a_{21})^2 = \\ &= 2a_{11}f_2(y_1) + 2a_{11}^2 p_{12} + 2a_{21}^2 p_{23} + 2p_{13}(a_{11} + a_{21})^2, \\ H''_{y_2 y_2} &= 2a_{22}f_2(y_2) + 2a_{12}^2 p_{12} + 2a_{22}^2 p_{23} + 2p_{13}(a_{12} + a_{22})^2, \\ H''_{y_1 y_2} &= a_{12}f_2(y_1) + a_{12}^2 f_2(y_2) + 2a_{11}a_{12}p_{12} + 2a_{21}a_{22}p_{23} + 2p_{13}(a_{12} + a_{22})(a_{11} + a_{21}). \end{aligned} \quad (4.3)$$

Подставив (4.2), (4.2') в (4.3), получим

$$\begin{aligned} H''_{y_1 y_1} H''_{y_2 y_2} - (H''_{y_1 y_2})^2 &= f_2^2(y_1) f_2^2(y_2) \left( a_{11} a_{22} \frac{1}{f_2(y_1) f_2(y_2)} - \left( \frac{a_{12}}{f_2(y_2)} + \frac{a_{21}}{f_2(y_1)} \right)^2 \right) = \\ &= f_2^2(y_1) f_2^2(y_2) \frac{1}{4(p_{12}p_{13} + p_{12}p_{23} + p_{23}p_{13})}, \end{aligned}$$

отсюда вытекает (4.1).  $\square$

Теперь асимптотика  $M\chi_1\chi_2$  значительно упрощается. При  $n \rightarrow +\infty$  имеем

$$\begin{aligned} n^2 M\chi_1\chi_2 &\sim 2 \iint_{x_1 < x_2} \frac{f(x_1, y_1^*) f(x_2, y_2^*)}{f_2(y_1^*) f_2(y_2^*)} dx_1 dx_2 = \\ &= \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} \frac{f(x_1, y_1^*) f(x_2, y_2^*)}{f_2(y_1^*) f_2(y_2^*)} dx_1 dx_2 = \left( \int_{-\infty}^{+\infty} \frac{f(x_1, y_1^*)}{f_2(y_1^*)} dx_1 \right)^2 = (nM\chi_1)^2. \end{aligned}$$

В итоге

$$DN \sim MN \sim \int_{-\infty}^{+\infty} \frac{f(x_1, y_1^*)}{f_2(y_1^*)} dx_1 = \lambda > 0.$$

## 5. Вид распределения числа совпадений

**Предложение** ([7], с. 265). Пусть случайные величины  $\chi_1, \dots, \chi_n$  принимают только значения 0 и 1 и симметрично зависимы. Тогда

1. моменты  $C_{nk} = M(\chi_1 \cdots \chi_k)$  образуют вполне монотонную последовательность (т. е. знаки конечных разностей элементов последовательности чередуются) для каждого  $n$ ;
2. существует случайная величина  $\lambda_n$ , распределение которой сосредоточено на решетке  $j/n, j = 0, \dots, n$ , такая, что  $M\lambda_n^k = C_{nk}$ ;
3. случайные величины  $N_n$  распределены по рандомизированному биномиальному закону

$$P(N_n = k) = \sum_{l=0}^n C_n^k \left(\frac{l}{n}\right)^k \left(1 - \frac{l}{n}\right)^{n-k} P\left(\lambda_n = \frac{l}{n}\right).$$

**Теорема 3.** Пусть  $N_n$  — число совпадений для объема выборки  $n$ ,

$$C_{nk} = M(\chi_1 \cdots \chi_k), \quad S_k = \lim_{n \rightarrow +\infty} n^k C_{nk}.$$

Тогда

- а) существует случайная величина  $\lambda$ , распределение которой сосредоточено на решетке  $j/n, j = 0, \dots, n$ , такая, что  $M\lambda_n^k = C_{nk}$ , и  $p(N_n = k) = \sum_{l=0}^n C_n^k l^k (1-l)^{n-k} P(\lambda_n = \frac{l}{n})$ ;
- б) для любого частичного слабого предела  $N$  последовательности  $N_n$  существует  $\mu \stackrel{D}{=} \lim_{n \rightarrow +\infty} n\lambda_n : M\mu^k = S_k$  и распределение  $N$  — рандомизированное по параметру распределение Пуассона

$$P(N = k) = \sum_{l=0}^{+\infty} \frac{e^{-l} l^k}{k!} P(\mu = l).$$

**Доказательство.** Легко видеть, что утверждение а) прямо следует из пп. 2, 3 предложения, т. к.  $\chi_1, \chi_2, \dots, \chi_k$  симметрично зависимы.

б) Пусть  $\mu_n = n\lambda_n, F_n$  — функция распределения  $\mu_n$ . Легко показать, что последовательность  $\mu_n$  стохастически ограничена. Действительно, из неравенства Чебышева

$$P(\mu_n \geq t) \leq \frac{1}{t^2} M(\mu_n^2).$$

Для фиксированного  $\varepsilon^*(n > n^*) \rightarrow P(\mu_n \geq t) \leq \frac{1}{t^2}(S_2 + \varepsilon^*)$ . Тогда  $\forall(\varepsilon > 0, n > n^*)$  существует  $a = \sqrt{S_2 + \varepsilon^* / \varepsilon} : P(\mu_n \geq a) \leq \varepsilon$ , что и означает стохастическую ограниченность последовательности  $\mu_n$ . Теперь из теоремы Хелли о выборе ([7], с. 307) ясно, что если последовательность  $F_n$  и не имеет предела, то все ее частичные пределы будут функциями распределения и будут обладать тем свойством, что их  $k$ -й момент равен  $S_k$ . Выберем любой из этих пределов. Пусть  $\mu$  — случайная величина, ему соответствующая. Далее утверждение б) становится очевидным.  $\square$

## 6. Асимптотическое распределение числа совпадений

Для нахождения предельного распределения числа совпадений воспользуемся методом моментов. Прежде всего методом математической индукции выведем рекуррентные соотношения для коэффициентов  $c_{jk}$  в (2.1).

При  $k = 1$ , очевидно,  $c_{11} = 1$ . Предположим, что известны  $c_{jk}, j = 1, \dots, k$ , и

$$\begin{aligned} MN_n^{k+1} &= M\left(\sum_{j=1}^k c_{jk} \sum_{i_1 \neq i_2 \neq \dots \neq i_j} \chi_{i_1} \cdots \chi_{i_j}\right) \left(\sum_{i=1}^n \chi_i\right) = \\ &= M\left(\sum_{j=1}^k c_{jk} \sum_{i_1 \neq \dots \neq i_{j+1}} \chi_{i_1} \cdots \chi_{i_{j+1}} + \sum_{j=1}^k j c_{jk} \sum_{i_1 \neq \dots \neq i_j} \chi_{i_1} \cdots \chi_{i_j}\right). \end{aligned}$$

Таким образом,  $c_{1,k+1} = 1, c_{j,k+1} = c_{j-1,k} + j c_{jk}$ .

Предположим, что  $c_{jk}$  суть коэффициенты полинома  $\Phi_k(\lambda) = \sum_{j=1}^k c_{jk} \lambda^j$ , тогда

$$\begin{aligned}\Phi_1(\lambda) &= 1, \\ \Phi_{k+1}(\lambda) &= \lambda(\Phi_k(\lambda) + \Phi'_k(\lambda)), \quad k = 2, 3, \dots\end{aligned}\tag{6.1}$$

Из (2.1) и (3.3) имеем  $\lim_{n \rightarrow \infty} MN_n^k = \sum_{j=1}^k c_{jk} \lambda^j = \Phi_k(\lambda)$ , где  $\lambda = \lim_{n \rightarrow \infty} nM\chi_1$ .

Начальные моменты случайной величины  $W$ , подчиненной распределению Пуассона, удовлетворяют (6.1). Действительно,  $MW = \lambda = \Phi_1(\lambda)$ . Предположим  $MW^k = \Phi_k(\lambda)$ . Это означает, что  $\phi^{(k)}(t) = (Me^{itw})^{(k)} = e^{\lambda(e^{it}-1)}(\Phi_k(\lambda e^{it}))i^k = e^{\lambda(e^{it}-1)} \sum_{j=1}^k c_{jk} \lambda^j e^{ijt} i^k$ . Дифференцируя последнее равенство, имеем  $\phi^{(k+1)}(t) = e^{\lambda(e^{it}-1)} \left( \sum_{j=1}^k \lambda e^{it} i c_{jk} \lambda^j e^{ijt} + ij c_{jk} \lambda^j e^{ijt} \right) i^k = e^{\lambda(e^{it}-1)} \Phi_{k+1}(\lambda e^{it}) i^{k+1}$ .

Следовательно,  $MW^{k+1} = \Phi_{k+1}(\lambda)$ .

Так как распределение Пуассона однозначно определяется своими моментами, предельное распределение  $N_n$  пуассоновское.

Заметим, что при  $\lambda < \infty$  этот результат следует из теоремы 3, поскольку

$$\begin{aligned}M\mu &= \lim_{n \rightarrow \infty} M\mu_n = \lambda < +\infty, \\ M\mu_n^2 &= (M\mu_n)^2 + o((M\mu_n)^2) = (M\mu_n)^0 + o(1),\end{aligned}$$

т. к.  $n^2 M\chi_1 \chi_2 \sim (nM\chi_1)^2$  и  $D\mu = \lim_{n \rightarrow \infty} D\mu_n = 0$ .

Покажем, что при  $\lambda \rightarrow \infty$  распределение числа совпадений  $N$  асимптотически нормально. Пусть  $\{W_n\}$  — последовательность случайных величин, подчиненных закону Пуассона с параметрами  $\lambda_n = nM\chi_1$ . Случайные величины  $N_n$  и  $W_n$  определены на одном и том же вероятностном пространстве  $\mathbf{Z}$  и сходятся по распределению к одной и той же случайной величине  $W$ , поэтому  $N_n - W_n \xrightarrow[n \rightarrow \infty]{P} 0$ . Имеем  $N_n = W_n + (N_n - W_n)$ , поскольку при  $\lambda \rightarrow \infty$  распределение  $W_n$  асимптотически нормально, таким же является и предельное распределение  $N_n$ , т.е.

$$P\left(\frac{N_n - MN_n}{\sqrt{DN_n}} < x\right) \rightarrow \Phi(x).$$

## Литература

1. De Groot M.H., Feder P.I., Goel P.K. *Matchmaking* // Ann. Math. Stat. — 1971. — V. 42. — №. 2. — P. 578–593.
2. Chew M.C. *On pairing observations from a distribution with monotone likelihood ratio* // Ann. Math. Stat. — 1973. — V. 1. — №3. — P. 433–445.
3. De Groot M.H., Goel P.K. *The matching problem for multivariate normal data* // Sankhya. — 1976. — V. 38. — № 1. — P. 14–29.
4. Золотухина Л.А., Латышев К.П. *Асимптотическое представление среднего числа совпадений элементов вариационных рядов двумерной выборки* // Зап. научн. семин. ЛОМИ. — 1978. — Т. 79. — С. 4–10.
5. Латышев К.П., Золотухина Л.А. *Интегральное представление дисперсии числа правильно угаданных пар в задаче о совпадении двумерной выборки* // Зап. научн. семин. ЛОМИ. — 1982. — Т. 136. — С. 113–120.
6. Федорюк М.В. *Асимптотика. Интегралы и ряды*. — М.: Наука, 1987. — 361 с.
7. Феллер В.И. *Введение в теорию вероятностей и ее применения*. Т. 2. — М.: Мир, 1984. — 751 с.

Санкт-Петербургский государственный  
морской технический университет

Поступили  
первый вариант 11.04.1997  
окончательный вариант 29.10.1998