

# Эконометрика-1

**Филатов Александр Юрьевич**

(Главный научный сотрудник, доцент ШЭМ ДВФУ)

[alexander.filatov@gmail.com](mailto:alexander.filatov@gmail.com)

<http://vk.com/alexander.filatov>, <http://vk.com/baikalreadings>

## Лекции 2.1-2.2

### Множественные связи.

### Порядковые и категоризованные переменные

# Линейная зависимость

# 2


## от нескольких объясняющих переменных

Парные коэффициенты корреляции  $r_{yx}^{(i)}$  не учитывают влияние на эту связь других переменных  $x^{(j)}$ . Следовательно, **необходим измеритель связи, очищенный от опосредованного влияния других переменных**, т.е. дающий оценку тесноты связи между  $y$  и  $x^{(i)}$  при условии, что остальные переменные зафиксированы на некотором постоянном уровне.

**Предположение:** простой (линейный) характер влияния всех остальных переменных на  $y$ :  $y = \theta_0 + \theta_1 x^{(1)} + \dots + \theta_p x^{(p)} + \varepsilon(X)$ .

Обозначим для удобства  $y \equiv x^{(0)}$ .

$$R = \begin{pmatrix} 1 & r_{01} & r_{02} & \dots & r_{0p} \\ r_{10} & 1 & r_{12} & \dots & r_{1p} \\ \dots & \dots & \dots & \dots & \dots \\ r_{p0} & r_{p1} & r_{p2} & \dots & 1 \end{pmatrix} \begin{array}{l} R_{ij} - \text{алгебраическое дополнение для } r_{ij} \text{ в} \\ \text{определителе корреляционной матрицы.} \\ R_{ij} = (-1)^{i+j} \det A_{ij}, \text{ матрица } A_{ij} \text{ получена из } R \\ \text{вычеркиванием } i\text{-строки и } j\text{-столбца.} \end{array}$$



# Частные (очищенные) коэффициенты корреляции

3

$r_{ij(-ij)} = \frac{-R_{ij}}{(R_{ii}R_{jj})^{1/2}}$  – частный коэффициент корреляции, коэффициент корреляции между переменными  $x^{(i)}$  и  $x^{(j)}$  при фиксированных значениях всех остальных переменных.

**Случай трех переменных:**

$$\hat{R} = \begin{pmatrix} 1 & r_{01} & r_{02} \\ r_{01} & 1 & r_{12} \\ r_{02} & r_{12} & 1 \end{pmatrix} \quad r_{01(2)} = \frac{r_{01} - r_{02}r_{12}}{\sqrt{(1 - r_{02}^2)(1 - r_{12}^2)}}$$

**Свойства частных коэффициентов корреляции:**

Проверка гипотезы о наличии/отсутствии связи, а также построение доверительного интервала для частного коэффициента корреляции  $k$ -порядка (при исключении влияния  $k$  переменных) происходит по тем же формулам, что и для парного коэффициента корреляции с единственным отличием: **объем выборки уменьшается на  $k$ .**

# Численные примеры

4

## Пример 1:

$n = 37$  – число исследуемых предприятий легкой промышленности,

$x^{(0)} \equiv y$  – качество ткани (в баллах),

$x^{(1)}$  – среднеемесячное число профилактических наладок автоматич. линии,

$x^{(2)}$  – среднеемесячное число обрывов нити.

$$\hat{R} = \begin{pmatrix} 1 & 0,105 & 0,024 \\ 0,105 & 1 & 0,996 \\ 0,024 & 0,996 & 1 \end{pmatrix} \quad r_{01(2)} = \frac{0,105 - 0,024 \cdot 0,996}{\sqrt{(1 - 0,024^2)(1 - 0,996^2)}} = 0,908,$$
$$r_{02(1)} = \frac{0,024 - 0,105 \cdot 0,996}{\sqrt{(1 - 0,105^2)(1 - 0,996^2)}} = -0,907.$$

**Связь есть, что согласуется с профессиональными представлениями!**

При нахождении доверительного интервала корректируем  $n = 37 - 1 = 36$ .

$$z = \text{ФИШЕР}(0,908) - \frac{0,908}{2(36-1)} = 1,502, \quad z \in [1,161; 1,843],$$
$$z \in \left[ 1,502 - \frac{1,96}{\sqrt{36-3}}; 1,502 + \frac{1,96}{\sqrt{36-3}} \right], \quad r \in [0,8214; 0,9511] \text{ при } \gamma = 0,95.$$

# Численные примеры

## Пример 2:

$n = 20$  – число лет метеонаблюдений,

$x^{(0)} \equiv y$  – урожайность кормовых трав,

$x^{(1)}$  – весеннее количество осадков,

$x^{(2)}$  – накопленная за весну сумма активных (выше  $+5,5^\circ\text{C}$ ) температур.

$$\hat{r}_{01} = 0,80, \quad \hat{r}_{02} = -0,40, \quad \hat{r}_{11} = -0,56.$$

$$\hat{R} = \begin{pmatrix} 1 & 0,80 & -0,40 \\ 0,80 & 1 & -0,56 \\ -0,40 & -0,56 & 1 \end{pmatrix}$$

$$r_{01(2)} = \frac{0,80 - 0,56 \cdot 0,40}{\sqrt{(1 - 0,56^2)(1 - 0,40^2)}} = 0,759,$$

$$r_{02(1)} = \frac{-0,40 + 0,80 \cdot 0,56}{\sqrt{(1 - 0,80^2)(1 - 0,56^2)}} = 0,097.$$

**Связь со второй переменной не отрицательная, а слабая положительная, что согласуется с профессиональными представлениями!**

$$r_{01(2)} \in [0,448; 0,898], \quad r_{02(1)} \in [-0,376; 0,526] \quad \text{при } \gamma = 0,95.$$



# Множественный коэффициент корреляции

6

**Множественный коэффициент корреляции** – коэффициент корреляции между  $y$  и линейной функцией регрессии, т.е. между  $y$  и наилучшей линейной комбинацией переменных  $x^{(1)}, \dots, x^{(p)}$  – той, для которой значение коэффициента корреляции максимально.

$$R_{y.X} = r(y, f(X)) = r\left(y, \theta_0 + \theta_1 x^{(1)} + \dots + \theta_p x^{(p)}\right)$$

**Свойства множественного коэффициента корреляции:**

1. При предположении о линейности связи

$$K_d(y; X) = R_{y.X}^2 = 1 - \frac{D\varepsilon}{Dy}$$

2. Вычисление множественного коэффициента корреляции по корреляционной матрице:

$$R_{y.X}^2 = 1 - \frac{|R|}{|R_{00}|}$$



# Множественный коэффициент корреляции

7

## Свойства множественного коэффициента корреляции:

3. Вычисление МКК по частным коэффициентам корреляции:

$$R_{y.X}^2 = 1 - \left(1 - r_{01}^2\right) \left(1 - r_{02(1)}^2\right) \left(1 - r_{03(12)}^2\right) \dots \left(1 - r_{0p(123\dots(p-1))}^2\right)$$
$$\hat{R}_{y.(x^{(1)}, x^{(2)})}^2 = 1 - \left(1 - \hat{r}_{01}^2\right) \left(1 - \hat{r}_{02(1)}^2\right) = 1 - \left(1 - 0,105^2\right) \left(1 - (-0,9068)^2\right) = 0,8243.$$
$$\hat{R}_{y.(x^{(1)}, x^{(2)})}^2 = 1 - \left(1 - \hat{r}_{02}^2\right) \left(1 - \hat{r}_{01(2)}^2\right) = 1 - \left(1 - 0,024^2\right) \left(1 - 0,9079^2\right) = 0,8243.$$

4. МКК мажорирует все парные и частные КК, характеризующие статистическую связь:  $R_{y.X}^2 \geq r_{0j(I_j)}^2$ , где  $I_j$  – любое подмножество  $\{1, \dots, p\}$ , не содержащее  $j$ .

5. Присоединение новой переменной не может уменьшить величины  $R$  вне зависимости от порядка присоединения:

$$R_{y.x^{(1)}}^2 \leq R_{y.(x^{(1)}, x^{(2)})}^2 \leq R_{y.(x^{(1)}, x^{(2)}, x^{(3)})}^2 \leq \dots \leq R_{y.(x^{(1)}, x^{(2)}, \dots, x^{(p)})}^2.$$



## Проверка гипотезы о наличии множественной линейной связи

Гипотеза о статистической независимости  $y$  и  $x^{(1)}, \dots, x^{(p)}$   $H_0: R_{y.X} = 0$ .

**1. Выбираем уровень значимости  $\alpha$ .**

Типичные значения  $\alpha = 0,05$ ; 0,1; 0,01, 0,001.

**2. Вычисляем эмпирическое значение критерия:**

$$F_{\text{эмп}} = \frac{\hat{R}_{y.X}^2}{1 - \hat{R}_{y.X}^2} \frac{n - p - 1}{p}.$$

**3. Вычисляем критическую точку:**

$$F_{\text{крит}} = F(\alpha; p; n - p - 1) = \text{ФРАСПОБР}(\alpha; p; n - p - 1).$$

**4. Сравниваем эмпирическое и критическое значение** и делаем вывод:

Если  $F_{\text{эмп}} > F_{\text{крит}}$ , то гипотеза  $H_0$  об отсутствии множественной линейной связи отвергается при уровне значимости  $\alpha$ , связь есть.





# Корреляционный анализ порядковых переменных

9

$x^{(1)}, \dots, x^{(p)}$  – порядковые переменные (обозначающие порядковое место в ряду, отсортированному по соответствующему показателю).

## Типовые задачи:

### 1. Анализ структуры упорядочений.

1. Точки разбросаны равномерно, нет согласованности между переменными.
2. Часть из  $p$  переменных близки между собой.
3. Часть из  $n$  объектов близки между собой.

### 2. Анализ совокупной согласованности переменных.

## Исследование степени согласованности мнений экспертов.

### 3. Построение единого группового упорядочения объектов, т.е. ранжировки $x^{(0)}$ , минимально удаленной от $x^{(1)}, \dots, x^{(p)}$ .

## Объединенные ранги:

Если есть неразличимые по некоторому свойству объекты, им всем приписывается единый ранг, равный среднему арифметическому.



# Ранговый коэффициент корреляции Спирмена

# 10

**Базовая формула:**

$$\hat{r}_{kj}^{(S)} = 1 - \frac{6}{n^3 - n} \sum_{i=1}^n \left( x_i^{(k)} - x_i^{(j)} \right)^2.$$

**Формула для случая объединенных рангов:**

$$\hat{r}_{kj}^{(S)} = \frac{1/6 \left( n^3 - n \right) - \sum_{i=1}^n \left( x_i^{(k)} - x_i^{(j)} \right)^2 - T^{(k)} - T^{(j)}}{\sqrt{\left( 1/6 \left( n^3 - n \right) - 2T^{(k)} \right) \left( 1/6 \left( n^3 - n \right) - 2T^{(j)} \right)}},$$

$$T^{(k)} = \frac{1}{12} \sum_{t=1}^{m^{(k)}} \left( \left( n_t^{(k)} \right)^3 - n_t^{(k)} \right), \quad m^{(k)} - \text{число групп объединенных рангов,}$$

$n_t^{(k)} - \text{число элементов в каждой групп.}$

**Свойства коэффициента Спирмена:**

$$\hat{r}_{kj}^{(S)} = 1, \text{ если } x_i^{(k)} = x_i^{(j)}, i = 1, \dots, n,$$

$$\hat{r}_{kj}^{(S)} = -1, \text{ если } x_i^{(k)} + x_i^{(j)} = n + 1, i = 1, \dots, n,$$

$$\hat{r}_{kj}^{(S)} \in (-1; 1) \text{ в остальных случаях.}$$



# Численные примеры

## Пример 1:

10 инвестиционных проектов, проранжированных 2 экспертами.

$$x^{(1)} = (1\ 2\ 3\ 4\ 5\ 6\ 7\ 8\ 9\ 10)$$

$$x^{(2)} = (2\ 3\ 1\ 4\ 6\ 5\ 9\ 7\ 8\ 10)$$

$$\begin{aligned} \hat{r}_{12}^{(S)} &= 1 - \frac{6}{990} (1 + 1 + 4 + \dots + 0) = \\ &= 1 - \frac{84}{990} = 0,915. \end{aligned}$$

## Пример 2:

10 стран, проранжированных по уровню жизни и качеству

институтов,  $x^{(1)} = (1\ 2,5\ 2,5)(4,5\ 4,5)(6,5\ 6,5)\ 8\ (9,5\ 9,5)$

$x^{(2)} = ((1,5\ 1,5)(4,5\ 4,5\ 4,5\ 4,5)(8\ 8\ 8)\ 10)$


$$T^{(1)} = \frac{1}{12} (2^3 - 2) \cdot 4 = \frac{24}{12} = 2,$$

$$T^{(2)} = \frac{1}{12} \left( (2^3 - 2) + (4^3 - 4) + (3^3 - 3) \right) = 7,5,$$

$$\hat{r}_{12}^{(S)} = \frac{\frac{990}{6} - (0,25 + 1 + \dots + 0,25) - 2 - 7,5}{\sqrt{\left( \frac{990}{6} - 2 \cdot 2 \right) \left( \frac{990}{6} - 2 \cdot 7,5 \right)}} = 0,911.$$

## Недостатки коэффициента Спирмена:

1. Недостаточная изученность статистических свойств.
2. Невозможность построения частных коэффициентов корреляции.
3. Необходимость полного пересчета при добавлении объекта.



# Ранговый коэффициент корреляции Кендалла

# 12

## Базовая формула:

$$\hat{r}_{kj}^{(K)} = 1 - \frac{4\nu(x^{(k)}, x^{(j)})}{n(n-1)}, \quad \nu(x^{(k)}, x^{(j)}) - \text{минимальное число обменов соседних элементов переменной } x^{(j)} \text{ для ее приведения к виду } x^{(k)}.$$

## Свойства коэффициента Кендалла:

$$\begin{aligned} \hat{r}_{kj}^{(K)} &= 1, \text{ если } x_i^{(k)} = x_i^{(j)}, i = 1, \dots, n, \\ \hat{r}_{kj}^{(K)} &= -1, \text{ если } x_i^{(k)} + x_i^{(j)} = n + 1, i = 1, \dots, n, \nu = n(n-1)/2, \\ \hat{r}_{kj}^{(K)} &\in (-1; 1) \text{ в остальных случаях.} \end{aligned}$$

**Расчет числа обменов неудобен,  $\nu$  – также число инверсий** (число расположенных в разном порядке пар элементов из  $x^{(k)}$  и  $x^{(j)}$ ).

**Удобно произвести сортировку данных по одной из переменных!**

$$\begin{pmatrix} 4 \\ 3 \\ 2 \\ 1 \end{pmatrix} \rightarrow \begin{pmatrix} 4 \\ 3 \\ 1 \\ 2 \end{pmatrix} \rightarrow \begin{pmatrix} 4 \\ 1 \\ 3 \\ 2 \end{pmatrix} \rightarrow \begin{pmatrix} 1 \\ 4 \\ 3 \\ 2 \end{pmatrix} \rightarrow \begin{pmatrix} 1 \\ 4 \\ 2 \\ 3 \end{pmatrix} \rightarrow \begin{pmatrix} 1 \\ 2 \\ 4 \\ 3 \end{pmatrix} \rightarrow \begin{pmatrix} 1 \\ 2 \\ 3 \\ 4 \end{pmatrix} \Leftrightarrow \begin{pmatrix} 1 \\ 2 \\ 3 \\ 4 \end{pmatrix} \begin{pmatrix} 4 \\ 3 \\ 2 \\ 1 \end{pmatrix} \begin{matrix} 3 \\ 2 \\ 1 \\ 0 \end{matrix} \quad \nu = 6, \quad \hat{r}_{12}^{(K)} = 1 - \frac{4 \cdot 6}{4 \cdot 3} = -1.$$



# Ранговый коэффициент корреляции Кендалла

Формула для случая объединенных рангов:

$$\hat{r}_{kj}^{*(K)} = \frac{\hat{r}_{kj}^{(K)} - \frac{2(u^{(k)} + u^{(j)})}{n(n-1)}}{\sqrt{\left(1 - \frac{2u^{(k)}}{n(n-1)}\right)\left(1 - \frac{2u^{(j)}}{n(n-1)}\right)}}, \quad u^{(k)} = \frac{1}{2} \sum_{t=1}^{m^{(k)}} n_t^{(k)} (n_t^{(k)} - 1).$$

**Пример 1:**

$$x^{(1)} = (1\ 2\ 3\ 4\ 5\ 6\ 7\ 8\ 9\ 10)$$

$$x^{(2)} = (2\ 3\ 1\ 4\ 6\ 5\ 9\ 7\ 8\ 10)$$

$$1\ 1\ 0\ 0\ 1\ 0\ 2\ 0\ 0\ 0$$

$$\nu(x^{(1)}, x^{(2)}) = 5,$$

$$\hat{r}_{12}^{(K)} = 1 - \frac{4 \cdot 5}{90} = 0,778.$$

**Пример 2:**

$$x^{(1)} = (1\ (2,5\ 2,5)(4,5\ 4,5)(6,5\ 6,5)\ 8\ (9,5\ 9,5))$$

$$x^{(2)} = ((1,5\ 1,5)(4,5\ 4,5\ 4,5\ 4,5)(8\ 8\ 8)\ 10)$$

$$u^{(1)} = \frac{1}{2}(4 \cdot 2 \cdot 1) = 4, \quad u^{(2)} = \frac{1}{2}(2 \cdot 1 + 4 \cdot 3 + 3 \cdot 2) = 10,$$

$$\hat{r}_{12}^{(K)} = \frac{90}{\sqrt{\left(1 - \frac{2 \cdot 4}{90}\right)\left(1 - \frac{2 \cdot 10}{90}\right)}} = 0,818.$$

# Проверка гипотезы о наличии связи между порядковыми переменными

Связь есть, если  $|\hat{r}^{(S)}| > t\left(\frac{\alpha}{2}; n-2\right) \sqrt{\frac{1 - (\hat{r}^{(S)})^2}{n-2}}$

или  $|\hat{r}^{(K)}| > u\left(1 - \frac{\alpha}{2}\right) \sqrt{\frac{2(2n+5)}{9n(n-1)}}$ .

$0,915 > \text{СТЮДРАСПОБР}(0,025; 8) \sqrt{(1 - 0,915^2)/8}$ ,  **$0,915 > 0,392$** .

$0,778 > \text{НОРМСТОБР}(0,975) \sqrt{\frac{2 \cdot (2 \cdot 10 + 5)}{9 \cdot 10 \cdot (10 - 1)}}$ ,  **$0,778 > 0,487$** .

Неравенства утверждают, что связь есть при уровне значимости  $\alpha = 0,05$ .

## Доверительный интервал для коэффициента Кендалла

$$r_{kj}^{(K)} \in \left[ \hat{r}_{kj}^{(K)} - u\left(\frac{1+\gamma}{2}\right) \sqrt{\frac{2}{n} \left(1 - (\hat{r}_{kj}^{(K)})^2\right)}; \hat{r}_{kj}^{(K)} + u\left(\frac{1+\gamma}{2}\right) \sqrt{\frac{2}{n} \left(1 - (\hat{r}_{kj}^{(K)})^2\right)} \right]$$

Интервал приближенный, формулу использовать для больших выборок!



# Связь между несколькими порядковыми переменными

# 15

**Коэффициент конкордации:**

$$\hat{W}(m) = \frac{12}{m^2(n^3 - n)} \sum_{i=1}^n \left( \sum_{j=1}^m x_i^{(k_j)} - \frac{m(n+1)}{2} \right)^2, \quad n - \text{число объектов,}$$

$m - \text{число переменных,}$   
 $k_1, \dots, k_m - \text{номера переменных.}$

$$\hat{W}(m) = \frac{\sum_{i=1}^n \left( \sum_{j=1}^m x_i^{(k_j)} - \frac{m(n+1)}{2} \right)^2}{\frac{1}{12} m^2 (n^3 - n) - m \sum_{j=1}^m T^{(k_j)}} - \text{при наличии объединенных рангов.}$$

**Свойства коэффициента конкордации:**

$$W(m) \in [0; 1],$$

$W(m) = 1$  при полном совпадении переменных,

$W(m) = 0$ , когда распределение случайно.

**Коэффициент конкордации не может быть отрицательным:**

если  $x_i^{(2)} = n - x_i^{(1)} + 1$ ,  $x_i^{(3)} = n - x_i^{(1)} + 1$ , то  $x_i^{(2)} = x_i^{(3)}$ .



# Численный пример

# 16

Ранжировка 10 инвестиционных проектов, осуществленная 3 экспертами.

$x^{(1)}$	$x^{(2)}$	$x^{(3)}$	$\Sigma$	$\Sigma - m\bar{x}$
1	2,5	2	5,5	-11
4,5	1	1	6,5	-10
2	2,5	4,5	9	-7,5
3	4,5	4,5	12	-4,5
4,5	4,5	4,5	13,5	-3
7,5	8	4,5	20	3,5
6	9	8	23	6,5
9	6,5	8	23,5	7
7,5	10	8	25,5	9
10	6,5	10	26,5	10

$$2 \ 2 \quad \left| \quad T^{(1)} = \frac{1}{12} (2^3 - 2) \cdot 2 = 1,$$

$$2 \ 2 \ 2 \quad \left| \quad T^{(2)} = \frac{1}{12} (2^3 - 2) \cdot 3 = 1,5,$$

$$4 \ 3 \quad \left| \quad T^{(3)} = \frac{1}{12} \left( (4^3 - 4) + (3^3 - 3) \right) = 7.$$

$$\hat{W}(3) = \frac{((-11)^2 + (-10)^2 + \dots + 10^2)}{\frac{1}{12} \cdot 3^2 \cdot (10^3 - 10) - 3 \cdot (1 + 1,5 + 7)} = 0,828.$$





# Проверка гипотезы о наличии связи между несколькими порядковыми переменными

# 17

Связь есть, если  $m(n-1)\hat{W}(m) > \chi^2(\alpha; n-1) = \text{ХИ2ОБР}(\alpha; n-1)$ .

## Пример 1:

$$\chi_{\text{эмп}}^2 = 3 \cdot 9 \cdot 0,828 = 22,35, \quad \chi_{\text{крит}}^2 = \text{ХИ2ОБР}(0,05; 9) = 16,92.$$

$22,35 > 16,92 \Rightarrow$  связь между 3 переменными есть при  $\alpha = 0,05$ .


## Пример 2:

$$m = 28, \quad n = 13, \quad \hat{W}(28) = 0,08$$

$$\chi_{\text{эмп}}^2 = 28 \cdot 12 \cdot 0,08 = 26,88, \quad \chi_{\text{крит}}^2 = \text{ХИ2ОБР}(0,05; 12) = 21,03$$

$26,88 > 21,03 \Rightarrow$  связь между 28 переменными есть при  $\alpha = 0,05$ .

**Замечание:** при большом количестве переменных даже малого значения коэффициента конкордации достаточно для вывода о наличии связи.



# Корреляционный анализ категоризованных переменных

# 18

$x^{(1)}, x^{(2)}$  – категоризованные переменные (переменные, описываемые конечным числом состояний).

## пол, социальная страта, сезон, фирма-производитель, ...

**Таблица сопряженности:**

	1	2	...	$m_2$		
1	$n_{11}$	$n_{12}$	...	$n_{1m_2}$	$n_{1\bullet} = \sum n_{1j}$	$w_{1\bullet} = n_{1\bullet}/n$
2	$n_{21}$	$n_{22}$	...	$n_{2m_2}$	$n_{2\bullet} = \sum n_{2j}$	$w_{2\bullet} = n_{2\bullet}/n$
...	...	...	...	...	...	...
$m_1$	$n_{m_11}$	$n_{m_12}$	...	$n_{m_1m_2}$	$n_{m_1\bullet} = \sum n_{m_1j}$	$w_{m_1\bullet} = n_{m_1\bullet}/n$
	$n_{\bullet 1} = \sum n_{j1}$	$n_{\bullet 2} = \sum n_{j2}$	...	$n_{\bullet m_2} = \sum n_{jm_2}$	$n$	
	$w_{\bullet 1} = n_{\bullet 1}/n$	$w_{\bullet 2} = n_{\bullet 2}/n$	...	$w_{\bullet m_2} = n_{\bullet m_2}/n$		

**Статистическая независимость переменных:**  $\frac{n_{ij}}{n} \approx \frac{n_{i\bullet}}{n} \frac{n_{\bullet j}}{n}$ ,  $w_{ij} \approx w_{i\bullet} w_{\bullet j}$ .

**Чем больше отклонение, тем больше показатель связи:**  $\delta_{ij} = w_{ij} - w_{i\bullet} w_{\bullet j}$ .



# Случай тесной связи и независимости переменных

# 19

##  $x^{(1)}$  – пол (муж/жен),  $x^{(2)}$  – уровень зарплаты (высокая/низкая),  $n = 100$ .

$$\begin{pmatrix} \boxed{50} & \boxed{0} & 50 & 0,5 \\ \boxed{0} & \boxed{50} & 50 & 0,5 \\ 50 & 50 & 100 & \\ 0,5 & 0,5 & & \end{pmatrix}, \Delta = \begin{pmatrix} 0,25 & -0,25 \\ 0,25 & 0,25 \end{pmatrix}.$$

**Максимально тесная связь**, знание значения одной переменной позволяет восстановить значение другой.

$$\begin{pmatrix} \boxed{25} & \boxed{25} & 50 & 0,5 \\ \boxed{25} & \boxed{25} & 50 & 0,5 \\ 50 & 50 & 100 & \\ 0,5 & 0,5 & & \end{pmatrix}, \Delta = \begin{pmatrix} 0 & 0 \\ 0 & 0 \end{pmatrix}.$$

**Полное отсутствие связи**, знание значения одной переменной не позволяет сделать никаких выводов о значении другой.

$$\begin{pmatrix} \boxed{28} & \boxed{42} & 70 & 0,7 \\ \boxed{12} & \boxed{18} & 30 & 0,3 \\ 40 & 60 & 100 & \\ 0,4 & 0,6 & & \end{pmatrix}, \Delta = \begin{pmatrix} 0 & 0 \\ 0 & 0 \end{pmatrix}.$$

**Полное отсутствие связи**, знание значения одной переменной не позволяет сделать никаких выводов о значении другой.



# Квадратичная сопряженность – характеристика тесноты связи

20

**Квадратичная сопряженность: два способа расчета:**

$$\hat{X}^2 = n \sum_{i=1}^{m_1} \sum_{j=1}^{m_2} \frac{\delta_{ij}^2}{w_{i \cdot} w_{\cdot j}} = n \left( \sum_{i=1}^{m_1} \sum_{j=1}^{m_2} \frac{n_{ij}^2}{n_{i \cdot} n_{\cdot j}} - 1 \right), \quad \hat{X}^2 \in [0; +\infty)$$

**Проверка гипотезы о наличии связи:**

$$\hat{X}^2 > X^2(\alpha; (m_1 - 1)(m_2 - 1)) \Rightarrow \text{связь есть при уровне значимости } \alpha.$$

**Коэффициент Крамера:**

Недостатком квадратичной сопряженности является неограниченность ее значений: при  $n \rightarrow \infty$   $X^2 \rightarrow \infty$ . Следовательно, желательно построить другой показатель, находящийся в привычном диапазоне  $[0; 1]$ .

$$\hat{C} = \sqrt{\frac{\hat{X}^2}{n \min\{m_1 - 1; m_2 - 1\}}} \in [0; 1]$$



# Численный пример

**Зависимость оплаты труда** (низкая; средняя; высокая) **от образования** (неполное среднее; среднее; среднее специальное; высшее; высшее со степенью),  $n = 300$ .

14	28	13	18	3	76	0,25
11	48	35	51	17	162	0,54
1	10	7	19	25	62	0,21
26	86	55	88	45	300	
0,09	0,29	0,18	0,29	0,15		

**Равномерное распределение**

7	22	14	22	11
14	46	30	48	24
5	18	11	18	9

$$\Delta = \begin{pmatrix} 0,025 & 0,021 & -0,013 & -0,014 & -0,028 \\ -0,010 & 0,005 & 0,018 & 0,012 & -0,024 \\ -0,015 & -0,026 & -0,015 & 0,003 & 0,052 \end{pmatrix} \frac{\delta_{ij}^2}{w_{i \cdot} w_{\cdot j}} = \begin{pmatrix} 0,028 & 0,006 & 0,000 & 0,003 & 0,021 \\ 0,002 & 0,000 & 0,003 & 0,001 & 0,007 \\ 0,012 & 0,011 & 0,006 & 0,000 & 0,088 \end{pmatrix}$$

$$\hat{X}^2 = 300 \cdot 0,188 = 56,48, \quad \hat{C} = \sqrt{\frac{56,48}{300 \min\{4; 2\}}} = 0,307.$$

$\chi_{\text{крит}}^2 = \text{ХИ2ОБР}(0,001; 4 \cdot 2) = 26,12$ , **56,48 > 26,12**  $\Rightarrow$  связь есть при  $\alpha=0,001$ .



*Спасибо  
за внимание!*

[alexander.filatov@gmail.com](mailto:alexander.filatov@gmail.com)

<http://vk.com/alexander.filatov>, <http://vk.com/baikalreadings>