

Понятие корреляционной зависимости

Многие задачи требуют установить и оценить зависимость между двумя или несколькими случайными величинами.

- Определение. Зависимость случайных величин называют *статистической*, если изменение одной величины влечет изменение распределения другой величины.
- Определение. Статистическая зависимость называется *корреляционной*, если при изменении одной величины изменяется среднее значение другой.

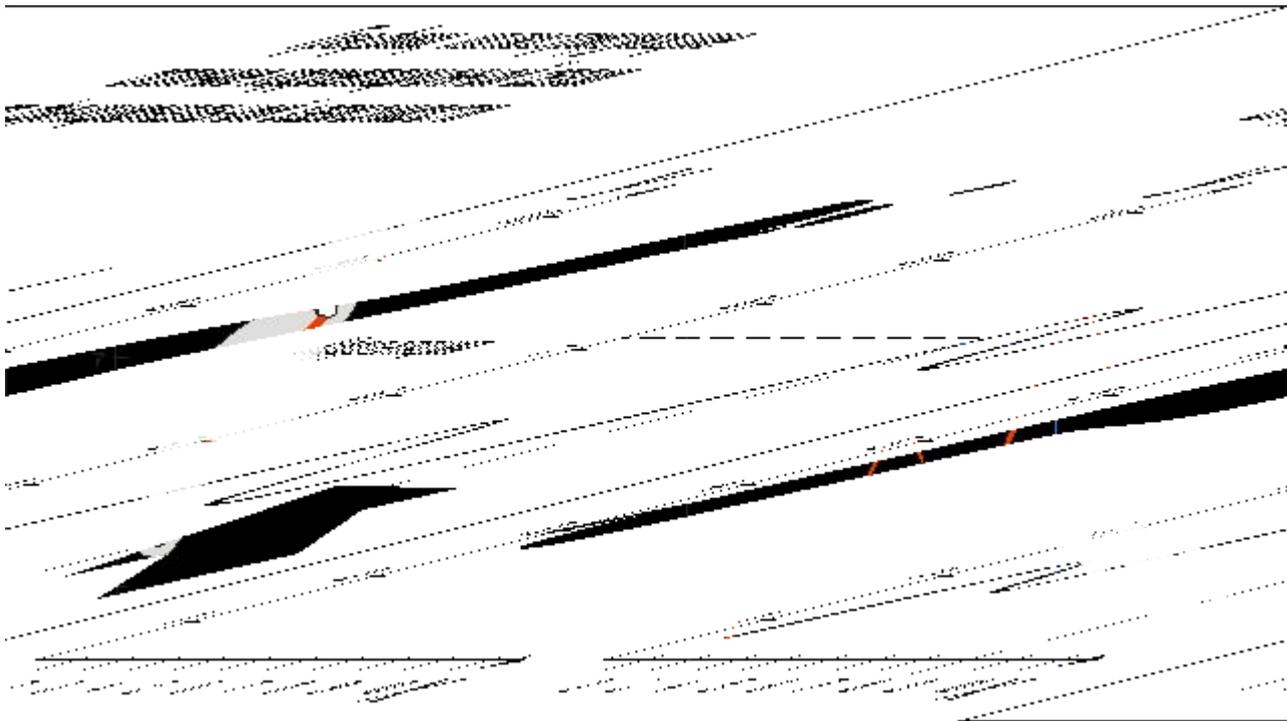
Если случайная величина представляет некоторый признак (например, статистические наблюдения некой экономической величины), то под **корреляцией** понимают – меру согласованности одного признака с другим, или с несколькими, либо взаимную согласованность группы признаков.

Ложная корреляция

- **Корреляционная зависимость** указывает на причинно-следственную связь изменений двух признаков. Однако, корреляционные методы не выявляют этой причинности, а лишь указывают на наличие некоторого соответствия. Признаки могут находиться не только во взаимной зависимости друг от друга, но и оба зависеть от какого-либо третьего воздействия, не включенного в область рассмотрения. Например, между двумя временными рядами (переменные, состоящие из наблюдений отстоящих на равные промежутки времени друг от друга) может быть сильная корреляционная зависимость, однако эта зависимость будет **ложной**, так как переменные сами зависят от времени.
- Таким образом, более корректно употреблять понятие **корреляционная связь**.

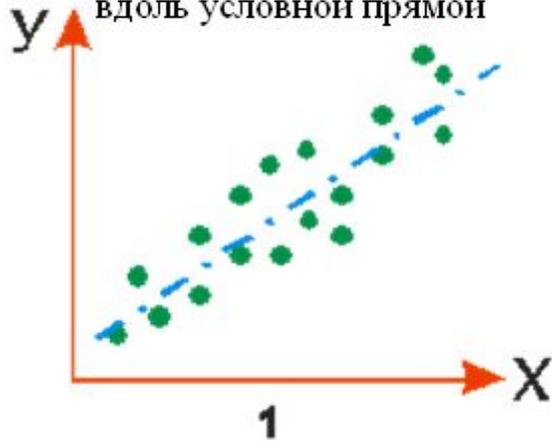
Отличие корреляционной от функциональной зависимости

Функциональная зависимость предполагает взаимно однозначное соответствие аргумента x и функции $y=f(x)$, вероятностная же зависимость допускает некий условный диапазон, в который предположительно (с такой-то долей вероятности) попадает значение признака y_i при значении x_i признака x .

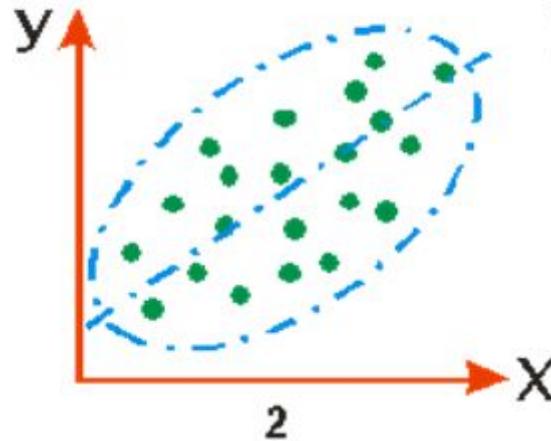


Примеры корреляционной зависимости

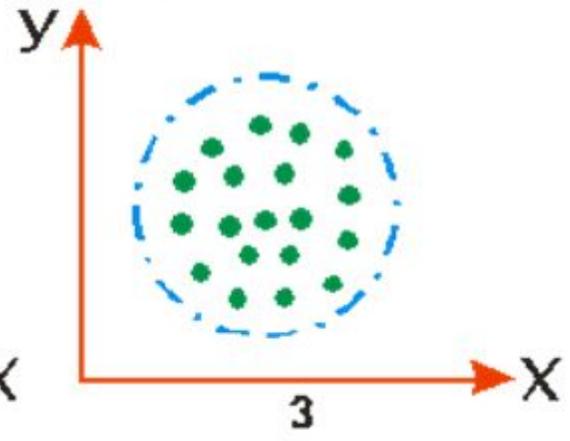
имеется значимая
положительная корреляция:
 $r > 0,8$
точки расположены примерно
вдоль условной прямой



имеется некоторая корреляция,
точки еще расположены вдоль
прямой, но уже хаотично,
вписываются в эллипс $0,5 < r < 0,6$



корреляция отсутствует:
точки расположены
хаотично (вписываются в
окружность) $r = 0$



Имеется значимая
положительная
корреляция $r = +1$, точки
расположены вдоль
прямой
Иначе: функциональная
зависимость

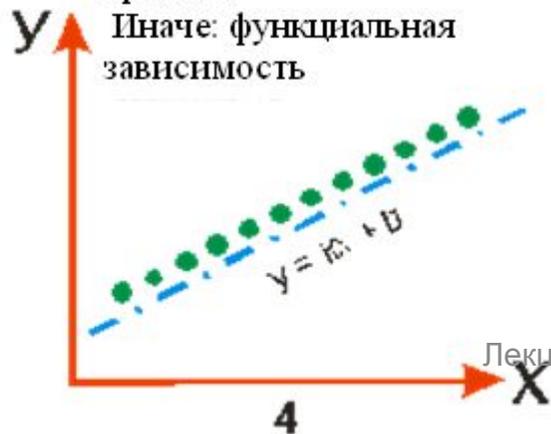
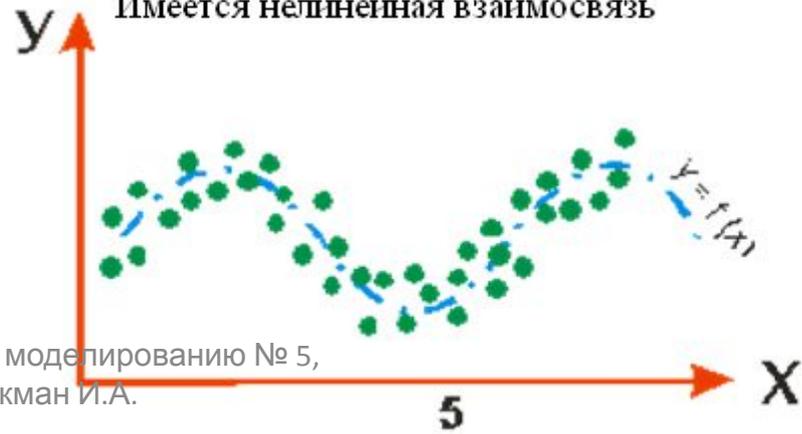
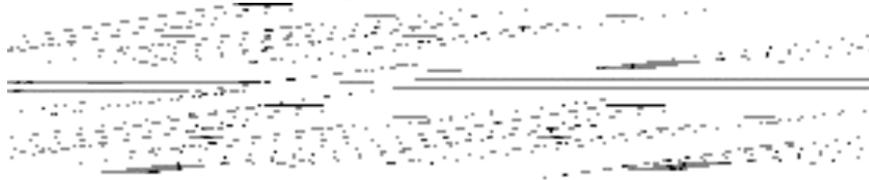


Диаграмма рассеяния показывает
однозначное соответствие: точки
расположены вдоль линии $y = \cos(x)$
Однако $r = 0$!
Имеется нелинейная взаимосвязь



Коэффициент корреляции Пирсона

Коэффициент корреляции Пирсона характеризует наличие линейной связи между признаками,



де x_i — значения, принимаемые в выборке X ,
 y_i — значения, принимаемые в выборке Y ;
 \bar{x} — средняя по X , \bar{y} — средняя по Y .

$$\bar{X} = \frac{1}{n} \sum_{t=1}^n X_t$$

$$\bar{Y} = \frac{1}{n} \sum_{t=1}^n Y_t$$

Ведем обозначения: ковариация признаков X и Y

$$\text{cov}(X, Y) = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n}$$

Средние квадратичные отклонения $\sigma_Y = \sqrt{\frac{\sum_{i=1}^n (y_i - \bar{y})^2}{n}}$

и $\sigma_X = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}}$

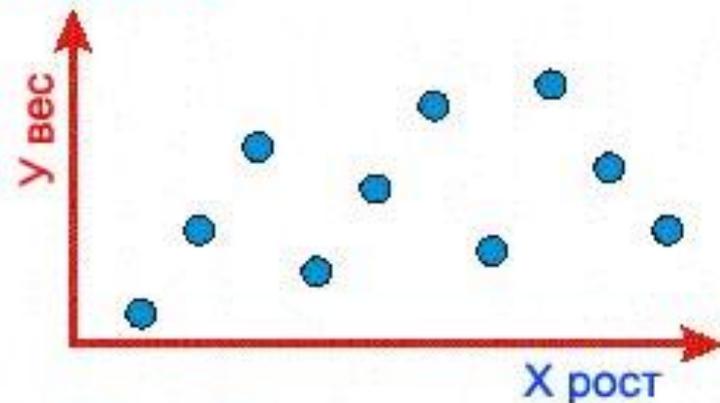
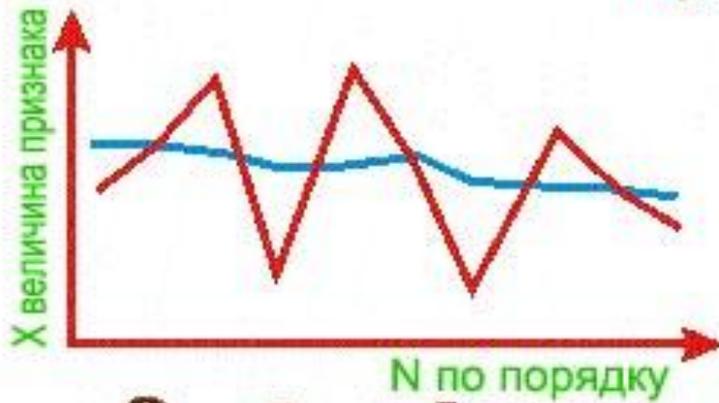
Тогда:

$$r_{xy} = \frac{\text{cov}(X, Y)}{\sigma_X \cdot \sigma_Y}$$

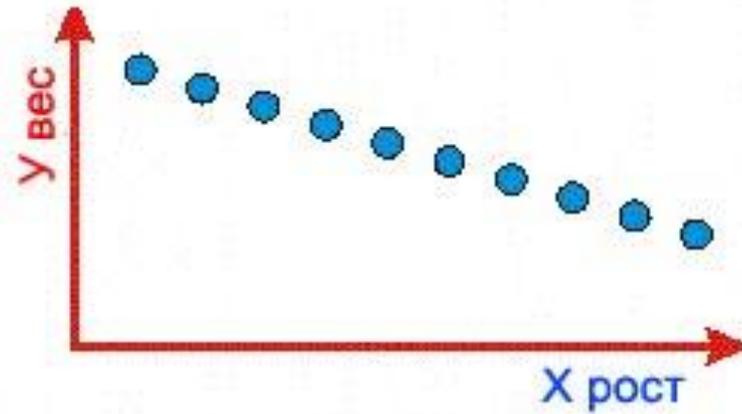
Значение коэффициента корреляции

- **сильная, или тесная** при коэффициенте корреляции $r > 0,70$;
- **средняя** при $0,50 < r < 0,69$;
- **умеренная** при $0,30 < r < 0,49$;
- **слабая** при $0,20 < r < 0,29$;
- **очень слабая** при $r < 0,19$.
- Если коэффициент корреляции положительный, то связь между признаками прямая: увеличение одного признака приводит к увеличению другого
- Если коэффициент корреляции отрицательный, то связь между признаками обратная: увеличение одного признака приводит к уменьшению другого
- В случае, если $r = 1, -1$, то связь между признаками функциональная!

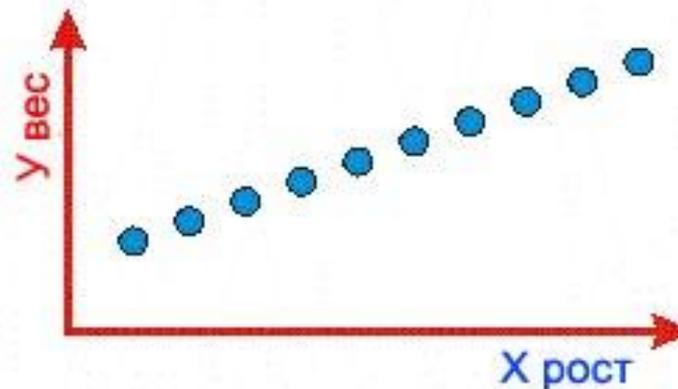
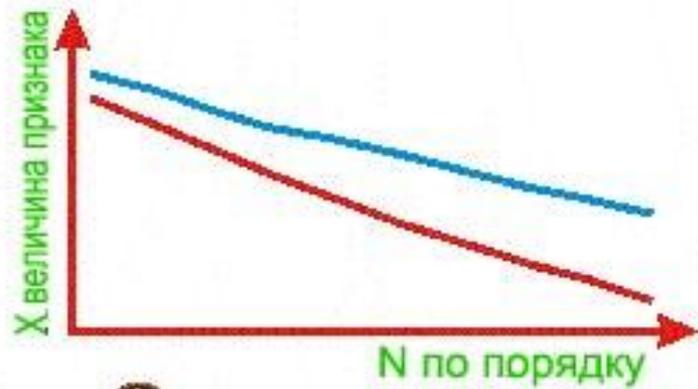
**Слабая линейная корреляция.
Почти при одинаковом росте все солдаты
то худые, то толстые.**



**Сильная линейная корреляция.
Чем ниже солдат, тем он толще.
(Кoeffициент корреляции отрицательный.)**



**Сильная линейная корреляция.
Чем выше солдат, тем он толще.**



Проверка значимости коэффициента корреляции Пирсона

Нулевая и альтернативная гипотезы имеют вид:

H_0 : коэффициент корреляции Пирсона r незначимый;

H_1 : коэффициент корреляции Пирсона r значим.

- Рассчитывается t -статистика по формуле:

$$t_{\text{расч.}} = \frac{r}{\sqrt{1-r^2}} \sqrt{(n-2)}$$

- Определяется $t_{\text{табл}}$ по таблице Стьюдента со степенями свободы $n-2$ и уровнем значимости α
- Если $|t_{\text{расч.}}| > t_{\text{табл}}$, то H_0 отклоняют на заданном уровне значимости, и считаем, что коэффициент корреляции Пирсона значимый.

Непараметрические показатели корреляции

Определение. Под **качественным** подразумевается признак, который невозможно измерить точно, но он позволяет сравнить объекты между собой и расположить их в порядке убывания или возрастания качества.

Под **ранжированием** будем понимать упорядочивание объектов согласно убыванию качественного признака

Для оценки степени связи качественных признаков используют **коэффициенты ранговой корреляции.**

Коэффициент корреляции Спирмена — мера линейной связи между случайными величинами. Корреляция Спирмена является **ранговой**, то есть для оценки силы связи используются не численные значения, а соответствующие им ранги.

Коэффициент корреляции Кендалла — мера линейной связи между случайными величинами

Схема нахождения коэффициента Корреляции Спирмена

1. Определить, какие два признака или две иерархии признаков будут участвовать в сопоставлении как переменные X и Y .
2. Проранжировать значения переменной X , присваивая ранг 1 наименьшему значению, и т.д. Занести ранги в первый столбец таблицы по порядку номеров испытуемых или признаков.
3. Проранжировать значения переменной Y , в соответствии с теми же правилами. Занести ранги во второй столбец таблицы по порядку номеров испытуемых или признаков.
4. Подсчитать разности d между рангами X и Y по каждой строке таблицы и занести в третий столбец таблицы.
5. Возвести каждую разность в квадрат: d^2 . Эти значения занести в четвертый столбец таблицы.
6. Подсчитать сумму d^2 .
7. При наличии одинаковых рангов рассчитать поправки: $T_a = \sum (a^3 - a) / 12$
где a - объем каждой группы одинаковых рангов в
ранговом ряду X ; b - объем каждой группы одинаковых
рангов в ранговом ряду Y .

Схема нахождения коэффициента Корреляции Спирмена

8. Рассчитать коэффициент ранговой корреляции r_s по формуле:
при отсутствии одинаковых рангов

$$r_s = 1 - 6 \cdot \frac{\sum d^2}{N \cdot (N^2 - 1)}$$

при наличии одинаковых рангов

$$r_s = 1 - 6 \cdot \frac{\sum d^2 + T_a + T_b}{N \cdot (N^2 - 1)}$$

где $\sum(d^2)$ - сумма квадратов разностей между рангами;

T_a и T_b - поправки на одинаковые ранги;

N - количество наблюдений признаков, участвовавших в ранжировании.

Проверка значимости коэффициента ранговой корреляции Спирмена

Нулевая и альтернативная гипотезы имеют вид:

H_0 : коэффициент ранговой корреляции Спирмена r_s незначимый;

H_1 : коэффициент ранговой корреляции Спирмена r_s значим.

- Рассчитывается t-статистика по формуле:

$$t_{расч.} = \frac{r_s}{\sqrt{1 - r_s^2}} \sqrt{(n - 2)}$$

- Определяется $t_{табл}$ по таблице Стьюдента со степенями свободы $n-2$ и уровнем значимости α
- Если $|t_{расч.}| > t_{табл}$, то H_0 отклоняют на заданном уровне значимости, и считаем, что коэффициент ранговой корреляции Спирмена значимый.

Схема нахождения коэффициента корреляции Кендалла

1. В порядке возрастания признака X выстраивают сопряженные наблюдения пар (x_i, y_i) и записывают их в таблицу.
2. Для каждого значения y_i определяют его ранг s_i , записывается в таблицу.
3. На последовательности рангов s_1, s_2, \dots, s_N определяют количество *инверсий*, т.е. нарушений порядка следования. Например, при $N = 4$ и последовательности рангов $\{1, 3, 4, 2\}$ имеем количество инверсий: 3 – количество инверсий для числа 1 (после числа 1 есть три значения, больше 1) и 1 – количество инверсий для числа 3 (после числа 3 есть одно значение, больше 3).
4. Формируют ряд значений в таблице из инверсий, если инверсий нет, то присваивают ячейке значение 0.
5. Рассчитывают сумму всех инверсий K : $K = \sum_{i=1}^N inv$
6. Определяют *коэффициент ранговой корреляции по Кендаллу*:

$$\tau_K = 1 - \frac{4 \cdot K}{N * (N - 1)}$$

Проверка значимости коэффициента ранговой корреляции Кендалла

Для проверки *значимости рангового коэффициента Кендалла*, то есть для проверки существенности корреляционной связи, выдвигают гипотезы:

H_0 : коэффициент ранговой корреляции Кендалла τ_K незначимый ($\tau_K=0$);

H_1 : коэффициент ранговой корреляции Кендалла τ_K значим ($\tau_K \neq 0$);

Рассчитывается Z-статистика по формуле:
$$z_{расч.} = \tau_K \sqrt{\frac{9N(NK+1)}{2(2N+5)}}$$

По таблице значений функции Лапласа определяем $z_{табл}$ из равенства для $\Phi(z_{табл}) = \frac{\alpha}{2}$ уровня значимости α .

Примечание: $z_{табл}$ можно определить также в модуле Вероятностный калькулятор, выбрав нормальное распределение Z , $p=1-\alpha$, $mean=0$, $st.dev=1$, и отметив режим двусторонней проверки гипотезы.
 $|z_{расч}| > z_{табл}$

Если $|z_{расч}| > z_{табл}$, следовательно, нулевую гипотезу о незначимости коэффициента Кендалла ($\tau_K=0$), можно отклонить на заданном уровне значимости α .

Схема нахождения коэффициента конкордации

- **Определение.** Множественный коэффициент ранговой корреляции, позволяющий определить тесноту связи между несколькими ранжированными признаками, называется **коэффициентом конкордации**.
1. Определить, какие признаки будут участвовать в сопоставлении как переменные (X, Y, Z, \dots).
 2. Проранжировать значения всех признаков, присваивая ранг 1 наименьшему значению, и т.д. Занести ранги в столбцы таблицы по порядку номеров признаков (R_x, R_y, R_z, \dots).
 3. Сформировать в таблице столбец из суммы всех рангов ($R_s = R_x + R_y + R_z + \dots$).
 4. Сформировать в таблице столбец из квадратов сумм всех рангов, полученных в п.3. R_s^2
 5. Определить по столбцу из сумм всех рангов (полученных в п.3) среднее значение, $\frac{\sum R_{S_i}}{n}$ где n – число наблюдений.

$$\overline{R_S} = \frac{\sum_{i=1}^n R_{S_i}}{n}$$

Схема нахождения коэффициента конкордации

6. Определить отклонение суммы квадратов рангов от средне квадратов рангов.

$$S = \sum_{i=1}^n R_{S_i}^2 - (\overline{R_S})$$

7. Вычислить коэффициент конкордации: $W = \frac{12 \cdot S}{m^2 \cdot (n^3 - n)}$

Где m - количество факторов (признаков сравнения),
 n – число наблюдений.

Для проверки *значимости коэффициента конкордации*, выдвигают гипотезы:

H_0 : коэффициент конкордации W незначимый ($W=0$);

H_1 : коэффициент конкордации W значим ($W \neq 0$);.

Рассчитывается χ^2 -статистика по формуле: $\chi^2 = \frac{12 \cdot S}{m \cdot n(n-1)}$

По таблице значений χ^2 -распределения определяем $\chi^2_{табл}$, для степени свободы $\nu=n$ и уровня значимости α .

Если $\chi^2 > \chi^2_{табл}$ следовательно, нулевую гипотезу о незначимости коэффициента конкордации ($W=0$), можно отклонить на заданном уровне значимости α .

Примечание, $\chi^2_{табл}$ можно определить из модуля **Вероятностный калькулятор** пакета Statistica.

Количественная оценка связи явлений различной природы: коэффициенты ассоциации и контингенции

Если качественные признаки состоят только из двух групп, то для определения тесноты связи двух качественных признаков применяют **коэффициенты ассоциации и контингенции.**

Схема нахождения коэффициентов

1. Пусть I явление имеет две альтернативы a и b , причем частоты их появления соответственно: n_a и n_b .

Пусть II явление имеет две альтернативы c и d , причем частоты их появления соответственно: n_c и n_d

2. Составляется таблица:

I	II	a	b	
c		n_{ac}	n_{bc}	n_c
d		n_{ad}	n_{bd}	n_d
		n_a	n_b	

Схема нахождения коэффициентов ассоциации и контингенции

3. Причем $n_a = n_{ac} + n_{ad}$ и $n_b = n_{bc} + n_{bd}$

$n_c = n_{ac} + n_{bc}$ и $n_d = n_{ad} + n_{bd}$

4. Определяется коэффициент ассоциации как:

$$K_a = \frac{n_{ac} \cdot n_{bd} - n_{bc} \cdot n_{ad}}{n_{ac} \cdot n_{bd} + n_{bc} \cdot n_{ad}}$$

Определяется коэффициент контингенции:

$$K_k = \frac{n_{ac} \cdot n_{bd} - n_{bc} \cdot n_{ad}}{\sqrt{n_a \cdot n_b \cdot n_c \cdot n_d}}$$

5. Связь считается подтвержденной если $K_a > 0,5$, а $K_k > 0,3$.

Примечание. Коэффициент контингенции всегда меньше коэффициента ассоциации.

Коэффициенты взаимной сопряженности

Если качественные признаки состоят из более чем двух групп, то для определения тесноты связи качественных признаков применяют **коэффициенты сопряженности Пирсона и Чупрова.**

Схема нахождения коэффициентов сопряженности

1. Пусть I явление имеет альтернативы a_I, b_I, c_I и т.д., причем частоты их появления соответственно: $n_{aI}, n_{bI}, n_{cI} \dots$

Пусть II явление имеет альтернативы a_{II}, b_{II}, c_{II} и т.д, причем частоты их появления соответственно: $n_{aII}, n_{bII}, n_{cII} \dots$

2. Составляется таблица:

	a_I	b_I	c_I		Итого
a_{II}	$n_{aI,aII}$	$n_{bI,aII}$	$n_{cI,aII}$...	n_{aII}
b_{II}	$n_{aI,bII}$	$n_{bI,bII}$	$n_{cI,bII}$...	n_{bII}
c_{II}	$n_{aI,cII}$	$n_{bI,cII}$	$n_{cI,cII}$...	n_{cII}

	n_{aI}	n_{bI}	n_{cI}	...	

Схема нахождения коэффициентов взаимной сопряженности

3. Причем $n_{aII} = n_{aI,aII} + n_{bI,aII} + n_{cI,aII}$; $n_{bII} = n_{aI,bII} + n_{bI,bII} + n_{cI,bII}$

$n_{cII} = n_{aI,cII} + n_{bI,cII} + n_{cI,cII}$

И $n_{aI} = n_{aI,aII} + n_{aI,bII} + n_{aI,cII}$; $n_{bI} = n_{bI,aII} + n_{bI,bII} + n_{bI,cII}$

$n_{cI} = n_{cI,aII} + n_{cI,bII} + n_{cI,cII}$

4. Определяется значение:

$$1 + \varphi^2 = \frac{\frac{(n_{aI,aII})^2}{n_{aI}} + \frac{(n_{bI,aII})^2}{n_{bI}} + \frac{(n_{cI,aII})^2}{n_{cI}} + \dots}{n_{aII}} + \frac{\frac{(n_{aI,bII})^2}{n_{aI}} + \frac{(n_{bI,bII})^2}{n_{bI}} + \frac{(n_{cI,bII})^2}{n_{cI}} + \dots}{n_{bII}} + \frac{\frac{(n_{aI,cII})^2}{n_{aI}} + \frac{(n_{bI,cII})^2}{n_{bI}} + \frac{(n_{cI,cII})^2}{n_{cI}} + \dots}{n_{cII}} + \dots$$

Схема нахождения коэффициентов *взаимной сопряженности*

5. Определяется **коэффициент взаимной сопряженности Пирсона**:

$$K_{II} = \sqrt{\frac{\varphi^2}{1 + \varphi^2}}$$

6. Определяется **коэффициент взаимной сопряженности Чупрова**:

$$K_{Ч} = \sqrt{\frac{\varphi^2}{\sqrt{(K_1 - 1)(K_2 - 1)}}$$

Где K_1 – число значений (групп) I-ого признака.

Где K_2 – число значений (групп) II-ого признака.

Чем ближе коэффициенты взаимной сопряженности **к единице**, тем теснее **связь**.

Бисериальный коэффициент корреляции

Связь между качественными альтернативами признака и количественными вариациями признака определяют на основе **бисериального коэффициента корреляции.**

Схема нахождения коэффициентов сопряженности

1. Пусть даны два качественных признака (категории или группы), для которых известны количественные характеристики. Количество наблюдений в I-ой группе – n_1 , в II-ой группе – n_2 . Общее количество наблюдений $n = n_1 + n_2$.

2. По каждому из признаков (группе) определяется среднее значение: $\overline{y_1}$ и $\overline{y_2}$

3. Определяются доли каждой группы в общем объеме:

Для I –ой группы: $p = n_1/n$

Для II-ой группы: $q = n_2/n$

4. Рассчитывается общее среднее значение для обеих групп (признаков)

$\overline{y_{общ}}$

Бисериальный коэффициент корреляции

5. Вычисляется среднее квадратичное отклонение фактических значений признака от среднего уровня:

$$\sigma_y = \sqrt{\frac{\sum_{i=1}^n (y_i - \overline{y_{общ}})^2}{n}}$$

6. По таблице значений функции Лапласа определяем $z_{табл}$ из равенства для $\Phi(z_{табл}) = \frac{1 - \alpha}{2}$ уровня значимости α .

7. Определяется **бисериальный коэффициент корреляции**:

$$r_{\bar{b}} = \frac{|\overline{y_2} - \overline{y_1}|}{\sigma_y} \cdot \frac{pq}{z_{табл}}$$

Чем ближе значение коэффициента к единице, тем теснее связь между признаками.