

ЛЕКЦИЯ 7

ТЕМА: Корреляционный анализ


Вопросы темы. Понятие корреляции случайных величин, коэффициент корреляции. Параметрические корреляционные меры. Коэффициент корреляции Пирсона. Непараметрические корреляционные меры. Коэффициентов корреляции Спирмена и Кенделла

Корреляционный анализ

Корреляционный анализ- метод, позволяющий обнаружить зависимость между несколькими случайными величинами.

Допустим, проводится независимое измерение различных параметров у одного типа объектов. Из этих данных можно получить качественно новую информацию - о взаимосвязи этих параметров.


Например, измеряем рост и вес человека, каждое измерение представлено точкой в двумерном пространстве:




Несмотря на то, что величины носят случайный характер, в общем наблюдается некоторая зависимость - величины коррелируют.

В данном случае это **положительная корреляция** (при увеличении одного параметра второй тоже увеличивается). Возможны также такие случаи:



Отрицательная корреляция:



Отсутствие корреляции:



Взаимосвязь между переменными необходимо охарактеризовать численно, чтобы, например, различать такие случаи:



Для этого вводится **коэффициент корреляции**. Он рассчитывается следующим образом:

Коэффициент корреляции Пирсона

Коэффициент корреляции Пирсона характеризует существование линейной зависимости между двумя величинами.

Пусть даны две выборки $x^m = (x_1, \dots, x_m)$, $y^m = (y_1, \dots, y_m)$; коэффициент корреляции Пирсона рассчитывается по формуле:

где \bar{x}, \bar{y} – выборочные средние x^m и y^m , s_x^2, s_y^2 – выборочные дисперсии, $r_{xy} \in [-1, 1]$.

Коэффициент корреляции Пирсона называют также теснотой линейной связи:

- $|r_{xy}| = 1 \Rightarrow x, y$ линейно зависимы,
- $r_{xy} = 0 \Rightarrow x, y$ линейно независимы.

Статистическая проверка наличия корреляции

Гипотеза: H_0 : отсутствует линейная связь между выборками x и y ($r_{xy} = 0$).


Статистика критерия:

$$T = \frac{r_{xy}\sqrt{n-2}}{\sqrt{1-r_{xy}^2}} \sim t_{n-2}$$
 – распределение Стьюдента с $n-2$ степенями свободы.

Критерий:

$T \in [t_\alpha, t_{1-\alpha}]$, где t_α есть α -квантиль распределения Стьюдента.

Слабые стороны



Четыре различных набора данных, коэффициент корреляции на которых равен 0.81

- Неустойчивость к выбросам.
- С помощью коэффициента корреляции Пирсона можно определить силу линейной зависимости между величинами, другие виды взаимосвязей выявляются методами регрессионного анализа.
- Необходимо понимать различие понятий "независимость" и "некоррелированность". Из первого следует второе, но не наоборот.

Для того, чтобы выяснить отношение между двумя переменными, часто необходимо избавиться от влияния третьей переменной. Рассмотрим пример 3-х переменных x, y, z . Исключим влияние переменной z :

$$r_{xy|z} = \frac{r_{xy} - r_{xz}r_{yz}}{\sqrt{(1-r_{xz}^2)(1-r_{yz}^2)}} \text{ – частный коэффициент корреляции.}$$

Для исключения влияния большего числа переменных:

$$r_{ij|vars} = \frac{-R_{ij}}{\sqrt{R_{ii}R_{jj}}},$$
$$R_{ij} = (-1)^{i+j} M_{ij},$$

где M_{ij} – главный минор матрицы коэффициентов корреляции переменных

Ранговая корреляция

Силу связи случайных величин можно оценивать, сравнивая не только численные значения этих случайных величин, но и соответствующие им ранги.

Заданы две выборки $x = (x_1, \dots, x_n)$, $y = (y_1, \dots, y_n)$, измеренные в ранговых шкалах. Примером выборки, измеренной в ранговых шкалах, могут служить экспертные оценки: эксперт проставляет оценки от 1 до 5 просмотренным n фильмам.

Выборкам x и y соответствуют последовательности рангов:

$R_x = (R_{x_1}, \dots, R_{x_n})$, где R_{x_i} — ранг i -го объекта в вариационном ряду выборки x ;

$R_y = (R_{y_1}, \dots, R_{y_n})$, где R_{y_i} — ранг i -го объекта в вариационном ряду выборки y .

Корреляция последовательностей рангов R_x и R_y называется **ранговой корреляцией**.

Коэффициент корреляции Спирмена

(Spearman rank correlation coefficient) — 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 инвариантен по отношению к любому монотонному преобразованию шкалы измерения.

Определение

Заданы две выборки $x = (x_1, \dots, x_n)$, $y = (y_1, \dots, y_n)$.

Вычисление корреляции Спирмена:

Коэффициент корреляции Спирмена вычисляется по формуле:

$$\rho = 1 - \frac{6}{n(n-1)(n+1)} \sum_{i=1}^n (R_i - S_i)^2, \quad \text{где } R_i - \text{ ранг наблюдения } x_i \text{ в ряду } x$$

, S_i - ранг наблюдения y_i в ряду y .

Коэффициент ρ принимает значения из отрезка $[-1; 1]$. Равенство $\rho = 1$ указывает на строгую прямую линейную зависимость, $\rho = -1$ на обратную.

Случай совпадающих наблюдений:

При наличии связок коэффициент корреляции Спирмена следует вычислять следующим образом:

$$\rho = \frac{\sum_{i=1}^n (R_i - (n+1)/2)(S_i - (n+1)/2)}{n(n-1)(n+1) - \Delta}, \text{III}$$

$$\Delta = \frac{1}{2} \sum_{i=1}^q u_i^x ((u_i^x)^2 - 1) + \frac{1}{2} \sum_{i=1}^f u_i^y ((u_i^y)^2 - 1)$$

где

Здесь q и f — количество связок в выборках x и y , $u_1^x, \dots, u_q^x, u_1^y, \dots, u_f^y$ — их размеры. Для элементов связок вычисляется средний ранг.

Обоснование критерия Спирмена:

Статистикой критерия Спирмена служит коэффициент корреляции Пирсона ρ ранговых наборов (R_1, \dots, R_n) и (S_1, \dots, S_n) . Он определяется следующей формулой:

$$\rho = \frac{\sum_{i=1}^n (R_i - \bar{R})(S_i - \bar{S})}{\left[\sum_{i=1}^n (R_i - \bar{R})^2 \sum_{i=1}^n (S_i - \bar{S})^2 \right]^{1/2}}. \quad \text{В} \quad \text{этой}$$

$$\bar{R} = \bar{S} = \frac{1}{n} \sum_{i=1}^n i = \frac{n+1}{2}$$

формуле

Воспользовавшись тем, что $\sum_{i=1}^n i^2 = \frac{n(n+1)(2n+1)}{6}$, получим:

$$\sum_{i=1}^n (R_i - \bar{R})^2 = \sum_{i=1}^n (S_i - \bar{S})^2 = \sum_{i=1}^n \left(i - \frac{n+1}{2}\right)^2 = \frac{n(n-1)(n+1)}{12}.$$

Переставив пары (R_i, S_i) в порядке возрастания первой компоненты, получим набор $(1, T_1), \dots, (n, T_n)$. Тогда перепишем коэффициент корреляции Спирмена в виде:

$$\rho = \frac{12}{n(n-1)(n+1)} \sum_{i=1}^n \left(i - \frac{n+1}{2}\right) \left(T_i - \frac{n+1}{2}\right).$$

Таким образом, ρ - линейная функция от рангов T_i . Правую часть равенства можно представить в следующем виде:^[1]

$$\rho = 1 - \frac{6}{n(n-1)(n+1)} \sum_{i=1}^n (i - T_i)^2 = 1 - \frac{6}{n(n-1)(n+1)} \sum_{i=1}^n (R_i - S_i)^2,$$

который наиболее удобен для вычислений.

Статистическая проверка наличия корреляции

Нулевая гипотеза H_0 : Выборки x и y не коррелируют ($\rho = 0$).


Статистика критерия: ρ .

Критерий (при уровне значимости α):

Против альтернативы $H_1: \rho > 0$:

если ρ больше табличного значения критерия Спирмена $r^{[1]}$ с уровнем значимости $\alpha/2$, то нулевая гипотеза отвергается.

Асимптотический критерий:



Критическая область критерия Спирмена.

Рассмотрим центрированную и нормированную статистику Спирмена:

$$\tilde{\rho} = \frac{\rho}{\sqrt{D\rho}}, \text{ где } D\rho = \frac{1}{n-1}.$$

Нулевая гипотеза отвергается (против альтернативы $H_2 — |\rho| > 0$), если:

$|\tilde{\rho}| \geq \Phi_{1-\alpha/2}$, где $\Phi_{1-\alpha}$ есть $(1-\alpha)$ -квантиль стандартного нормального распределения.

Аппроксимация удовлетворительно работает, начиная с $n \geq 50$.

Поправка:

В 1978 году Р. Иман и У. Коновер предложили следующую поправку, значительно повышающую точность аппроксимации. Она использует линейную комбинацию нормальной и стьюдентовской квантилей. Положим:


$$\tilde{\rho}^* = \frac{1}{2}\tilde{\rho} \left[\sqrt{n-1} + \sqrt{\frac{n-2}{1-(\tilde{\rho})^2}} \right].$$

Гипотеза H_0 отвергается в пользу альтернативы $H_1 (\rho > 0)$, если $\tilde{\rho}^* \geq (x_{1-\alpha} + y_{1-\alpha})/2$, где $x_{1-\alpha}$, $y_{1-\alpha}$ обозначают соответственно квантили уровня $(1-\alpha)$ стандартного нормального распределения и распределения Стьюдента с $n-2$ степенями свободы.

Примеры

Ниже приведены примеры вычисления корреляций Кенделла и Спирмена. Значения коэффициентов указаны над каждым изображением в виде (τ, ρ) , где τ - корреляция Кенделла, ρ - Спирмена. Заметно, что в большинстве случаев $|\rho| > |\tau|$. Объяснение этого эффекта приводится ниже.


Направление линейной зависимости



Корреляции Кенделла и Спирмена. Нормальные сгущения.

Коэффициенты корреляции реагируют на изменение направления и зашумлённость линейной зависимости между переменными.

Наклон линейного тренда



Корреляции Кенделла и Спирмена. Вращающаяся полоса.


Коэффициенты корреляции реагируют на изменение направления, но не реагируют на изменение наклона тренда. На первом, четвёртом и седьмом рисунках дисперсия одной из переменных близка к нулю, поэтому не удаётся зафиксировать факт линейной зависимости.

Нелинейная зависимость


(0; 0.01)



(-0.18; -0.27)



(0.01; 0.02)



(-0.01; -0.02)



Корреляции Кенделла и Спирмена. Нелинейная зависимость.

Корреляции Кенделла и Спирмена не отражают меры нелинейной зависимости между переменными.

Линейная и нелинейная зависимости

На каждой из приведённых ниже иллюстраций осуществляется переход от линейной зависимости к нелинейной. Коэффициенты корреляции Кенделла и Спирмена реагируют на это одинаковым образом.

(0.84; 0.97)



(0.65; 0.86)



(0.12; 0.16)



(0; 0)



(0; 0)



Корреляции Кенделла и Спирмена. Перекрещенные полосы.

(1; 1)



(0.79; 0.95)



(0.6; 0.82)



(0.42; 0.63)



(0.2; 0.3)



Корреляции Кенделла и Спирмена. Расширяющаяся полоса.

(0.7; 0.9)

(0.69; 0.88)

(0.65; 0.86)

(0.6; 0.82)

(0.



Корреляции Кенделла и Спирмена. Синусоида с переменной амплитудой.

По мере смены линейной зависимости нелинейной значения коэффициентов корреляции падают.

Связь коэффициентов корреляции Спирмена и Пирсона

В случае выборок из нормального распределения коэффициент корреляции Спирмена ρ может быть использован для оценки коэффициента корреляции Пирсона r по формуле:

$$r = 2 \sin \frac{\pi}{6} \rho$$

Связь коэффициентов корреляции Спирмена и Кенделла

Выборкам x и y соответствуют последовательности рангов:

$R_x = (R_{x_1}, \dots, R_{x_n})$, где R_{x_i} — ранг i -го объекта в вариационном ряду выборки x ;

$R_y = (R_{y_1}, \dots, R_{y_n})$, где R_{y_i} — ранг i -го объекта в вариационном ряду выборки y .

Проведем операцию упорядочивания рангов.

Расположим ряд значений x_i в порядке возрастания величины: $x_1 \leq x_2 \leq \dots \leq x_n$. Тогда последовательность рангов упорядоченной выборки x будет представлять собой последовательность натуральных чисел $1, 2, \dots, n$. Значения y , соответствующие значениям x , образуют в этом случае некоторую последовательность рангов $T = (T_1, \dots, T_n)$:

$$(R_{x_i}, R_{y_i}) \xrightarrow{sort} (i, T_i), i = 1, \dots, n.$$

Коэффициент корреляции Кенделла τ и коэффициент корреляции Спирмена ρ выражаются через ранги следующим образом:

$$\rho = 1 - \frac{12}{n^3 - n} \sum_{i < j} (j - i) [T_i > T_j];$$

$$\tau = 1 - \frac{4}{n^2 - 1} \sum_{i < j} [T_i > T_j];$$

Заметно, что в случае ρ инверсиям придаются дополнительные веса $(j-i)$, таким образом ρ сильнее реагирует на несогласие ранжировок, чем τ . Этот эффект проявляется в приведённых выше примерах: в большинстве из них $|\rho| > |\tau|$.

Утверждение.^[11] Если выборки x и y не коррелируют (выполняется гипотеза H_0), то величины ρ и τ сильно закоррелированы. Коэффициент корреляции между ними можно вычислить по формуле:

$$\text{corr}(\rho, \tau) = \frac{2n+2}{\sqrt{4n^2+10n}}.$$

История
