Прикладной статистический анализ данных. 6. Анализ зависимостей.

Рябенко Евгений
riabenko.e@gmail.com

I/2016

Задача исследования взаимосвязи между признаками

Дано: значения признаков X_1, X_2 измерены на объектах $1, \ldots, n$.
Эквивалентная формулировка: имеются связанные выборки $X_1^n = (X_{11}, \ldots, X_{1n})$ и $X_2^n = (X_{21}, \ldots, X_{2n})$.

Насколько сильно признаки X_1, X_2 связаны между собой?

Статистическая взаимосвязь между случайными величинами — **корреляция**.

Корреляция и причинность

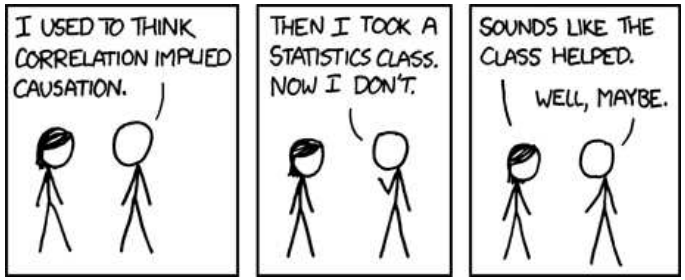

Корреляция — статистическая взаимосвязь между случайными величинами; не является достаточным условием причинно-следственной:

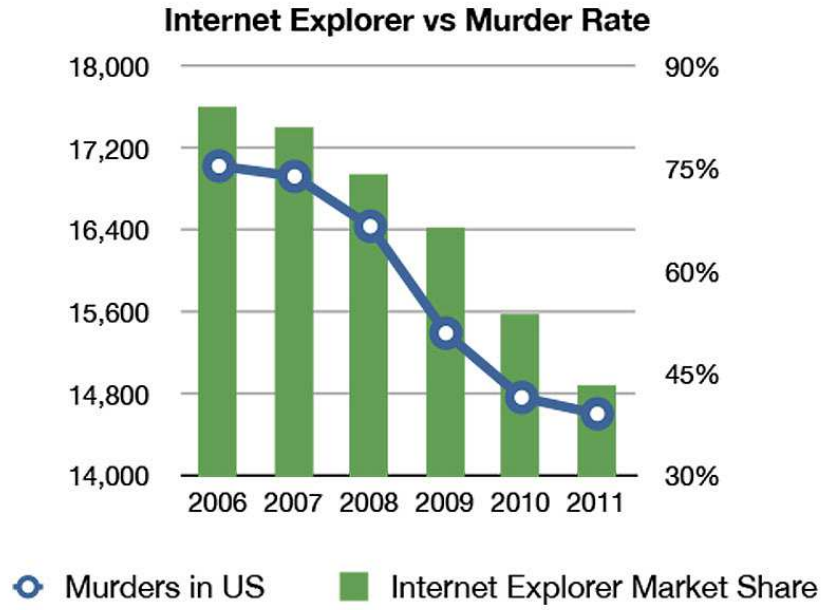

Другие примеры: `http://www.tylervigen.com/`

Корреляция Пирсона

Коэффициент корреляции Пирсона $r_{X_1X_2}$ случайных величин X_1 и X_2 — мера силы **линейной** корреляции между ними:

$$r_{X_1X_2} = \frac{\mathbb{E}\left(\left(X_1 - \mathbb{E}X_1\right)\left(X_2 - \mathbb{E}X_2\right)\right)}{\sqrt{\mathbb{D}X_1\mathbb{D}X_2}}.$$

$r_{X_1X_2} \in [-1, 1]$.

Пусть имеется простая выборка пар $\left(X_{1i}, X_{2i}\right), i = 1, \ldots, n$.
Выборочный коэффициент корреляции Пирсона:

$$r_{X_1X_2} = \frac{\sum\limits_{i=1}^{n}\left(X_{1i} - \bar{X}_1\right)\left(X_{2i} - \bar{X}_2\right)}{\sqrt{\sum\limits_{i=1}^{n}\left(X_{1i} - \bar{X}_1\right)^2 \sum\limits_{i=1}^{n}\left(X_{2i} - \bar{X}_2\right)^2}}.$$

Корреляция Пирсона

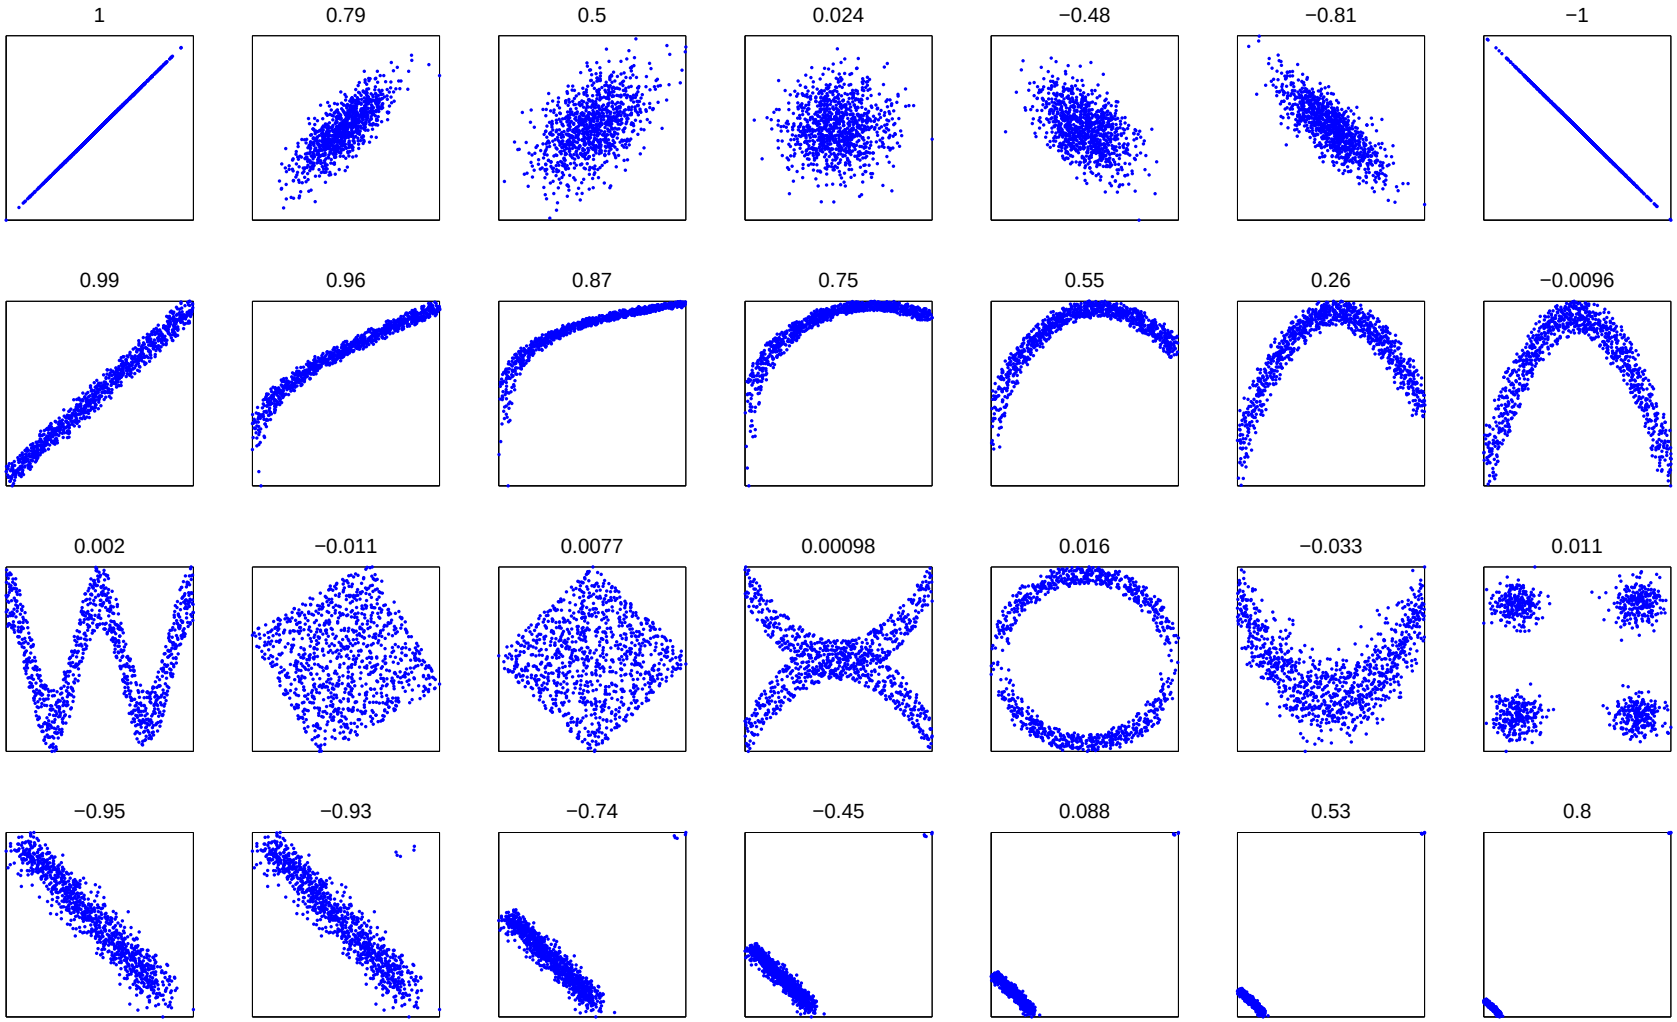

http://guessthecorrelation.com/

Корреляция Пирсона

Недостатки выборочного коэффициента Пирсона:

- для распределений, отличных от нормального, перестаёт быть эффективной оценкой популяционного коэффициента корреляции;
- служит мерой только линейной взаимосвязи;
- неустойчив к выбросам.

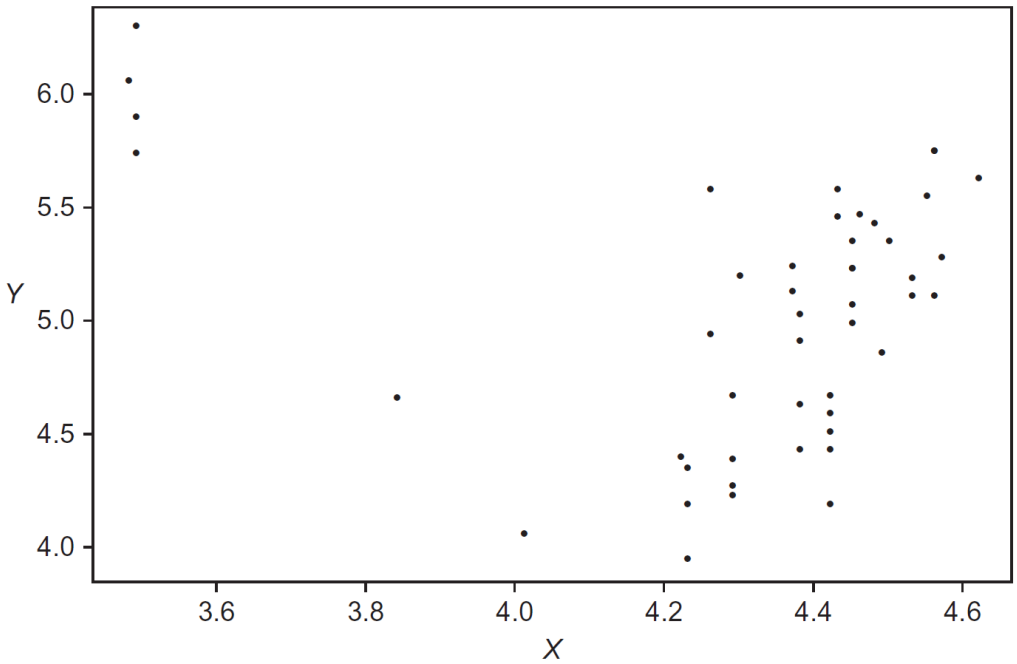

Корреляция между логарифмами эффективной температуры на поверхности звезды (X) и интенсивности её света (Y) получается отрицательной $(r_{XY} = -0.21)$ из-за наличия в выборке красных гигантов.

Критерий Стьюдента

выборки: $X_1^n = (X_{11}, \ldots, X_{1n})$,
$X_2^n = (X_{21}, \ldots, X_{2n})$, выборки связанные,
$(X_1, X_2) \sim N(\mu, \Sigma)$;

нулевая гипотеза: $H_0 : r_{X_1 X_2} = 0$;

альтернатива: $H_1 : r_{X_1 X_2} <\neq> 0$;

статистика: $T(X_1^n, X_2^n) = \frac{r_{X_1 X_2}\sqrt{n-2}}{\sqrt{1-r_{X_1 X_2}^2}}$;

$T(X_1^n, X_2^n) \sim St(n-2)$ при H_0.

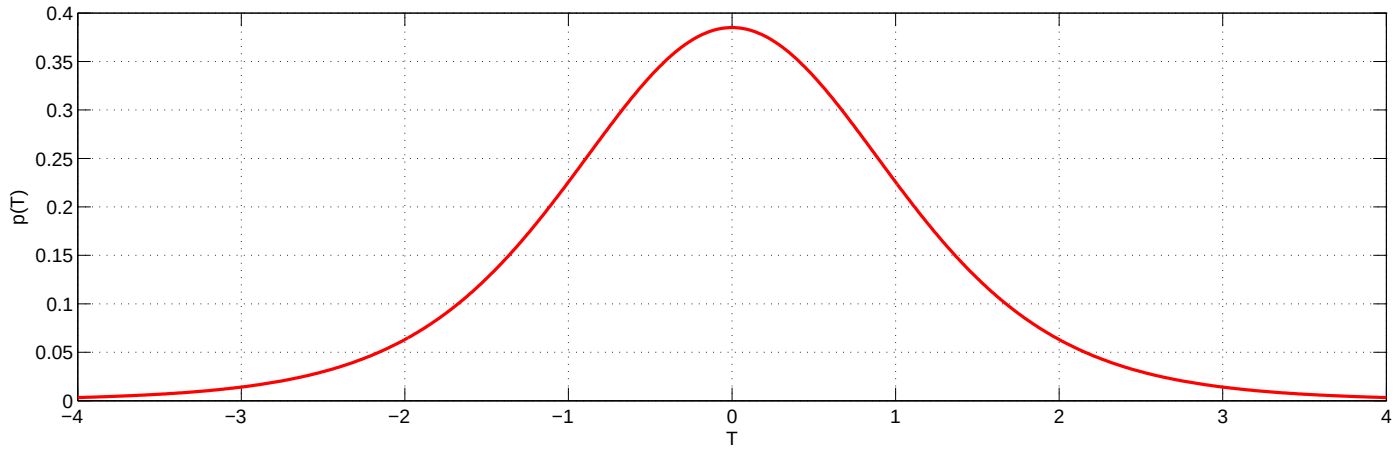

Критерий Стьюдента

Доверительный интервал для коэффициента корреляции Пирсона:

$$\left[r_{X_1X_2} + \frac{t_{n-2,\alpha/2}\left(1 - r^2_{X_1X_2}\right)}{\sqrt{n}}, r_{X_1X_2} - \frac{t_{n-2,\alpha/2}\left(1 - r^2_{X_1X_2}\right)}{\sqrt{n}}\right].$$

С использованием преобразования Фишера:

$$\left[\tanh\left(\operatorname{arctanh} r_{X_1X_2} + \frac{z_{\alpha/2}}{\sqrt{n-3}}\right), \tanh\left(\operatorname{arctanh} r_{X_1X_2} - \frac{z_{\alpha/2}}{\sqrt{n-3}}\right)\right].$$

Критерий Стьюдента

Пример (Kanji, критерий 12): для двух марок зубной пасты, одна из которых рекламируется по телевизору, а другая нет, участники опроса (30 человек) выставляют оценки в баллах от 1 до 20 в соответствии со своими предпочтениями. Коэффициент корреляции Пирсона между оценками двух марок составляет 0.32, значимо ли эта величина отличается от нуля?

$H_0 : r_{X_1 X_2} = 0.$
$H_1 : r_{X_1 X_2} \neq 0 \Rightarrow p = 0.0847.$

Доверительный интервал: $[-0.0157, 0.6557]$.
С использованием преобразования Фишера: $[-0.0455, 0.6100]$.

Перестановочный критерий

выборки: $X_1^n = (X_{11}, \ldots, X_{1n})$,
$X_2^n = (X_{21}, \ldots, X_{2n})$, выборки связанные;
нулевая гипотеза: $H_0 \colon r_{X_1X_2} = 0$;
альтернатива: $H_1 \colon r_{X_1X_2} <\neq> 0$;
статистика: $T\left(X_1^n, X_2^n\right) = r_{X_1X_2}$.

Нулевое распределение $T\left(X_1^n, X_2^n\right)$ порождается группой перестановок

$$G = \left\{g \colon gX_2^n = (X_{2\pi_1}, \ldots, X_{2\pi_n})\right\},$$

где $\pi_1, \ldots, \pi_n$ — перестановка индексов $1, \ldots, n$;

$$|G| = n!$$

Достигаемый уровень значимости:

$$p\left(t\right) = \begin{cases} \dfrac{\sum\limits_{g \in G}\left[T\left(X_1^n, gX_2^n\right) \leq\geq T\left(X_1^n, X_2^n\right)\right]}{n!}, & H_1 \colon r_{X_1X_2} <> 0, \\ \dfrac{\sum\limits_{g \in G}\left[\left|T\left(X_1^n, gX_2^n\right)\right| \geq \left|T\left(X_1^n, X_2^n\right)\right|\right]}{n!}, & H_1 \colon r_{X_1X_2} \neq 0. \end{cases}$$

Перестановочный критерий

Пример: в предыдущем примере

$H_0 : r_{X_1 X_2} = 0.$
$H_1 : r_{X_1 X_2} \neq 0 \Rightarrow p = 0.0564.$

Корреляция Спирмена

Коэффициент корреляции Спирмена $\rho_{X_1X_2}$ случайных величин X_1 и X_2 — мера силы **монотонной** корреляции между ними; равен коэффициенту корреляции Пирсона между рангами наблюдений.

Выборочный коэффициент корреляции Спирмена:

$$\rho_{X_1X_2} = \frac{\sum\limits_{i=1}^{n} \left(\operatorname{rank}(X_{1i}) - \frac{n+1}{2}\right)\left(\operatorname{rank}(X_{2i}) - \frac{n+1}{2}\right)}{\frac{1}{12}\left(n^3 - n\right)} =$$

$$= 1 - \frac{6}{n^3 - n}\sum_{i=1}^{n}\left(\operatorname{rank}(X_{1i}) - \operatorname{rank}(X_{2i})\right)^2,$$

$\operatorname{rank}(X_{1i}), \operatorname{rank}(X_{2i})$ — ранги i-х наблюдений в соответствующих выборках.

Корреляция Спирмена

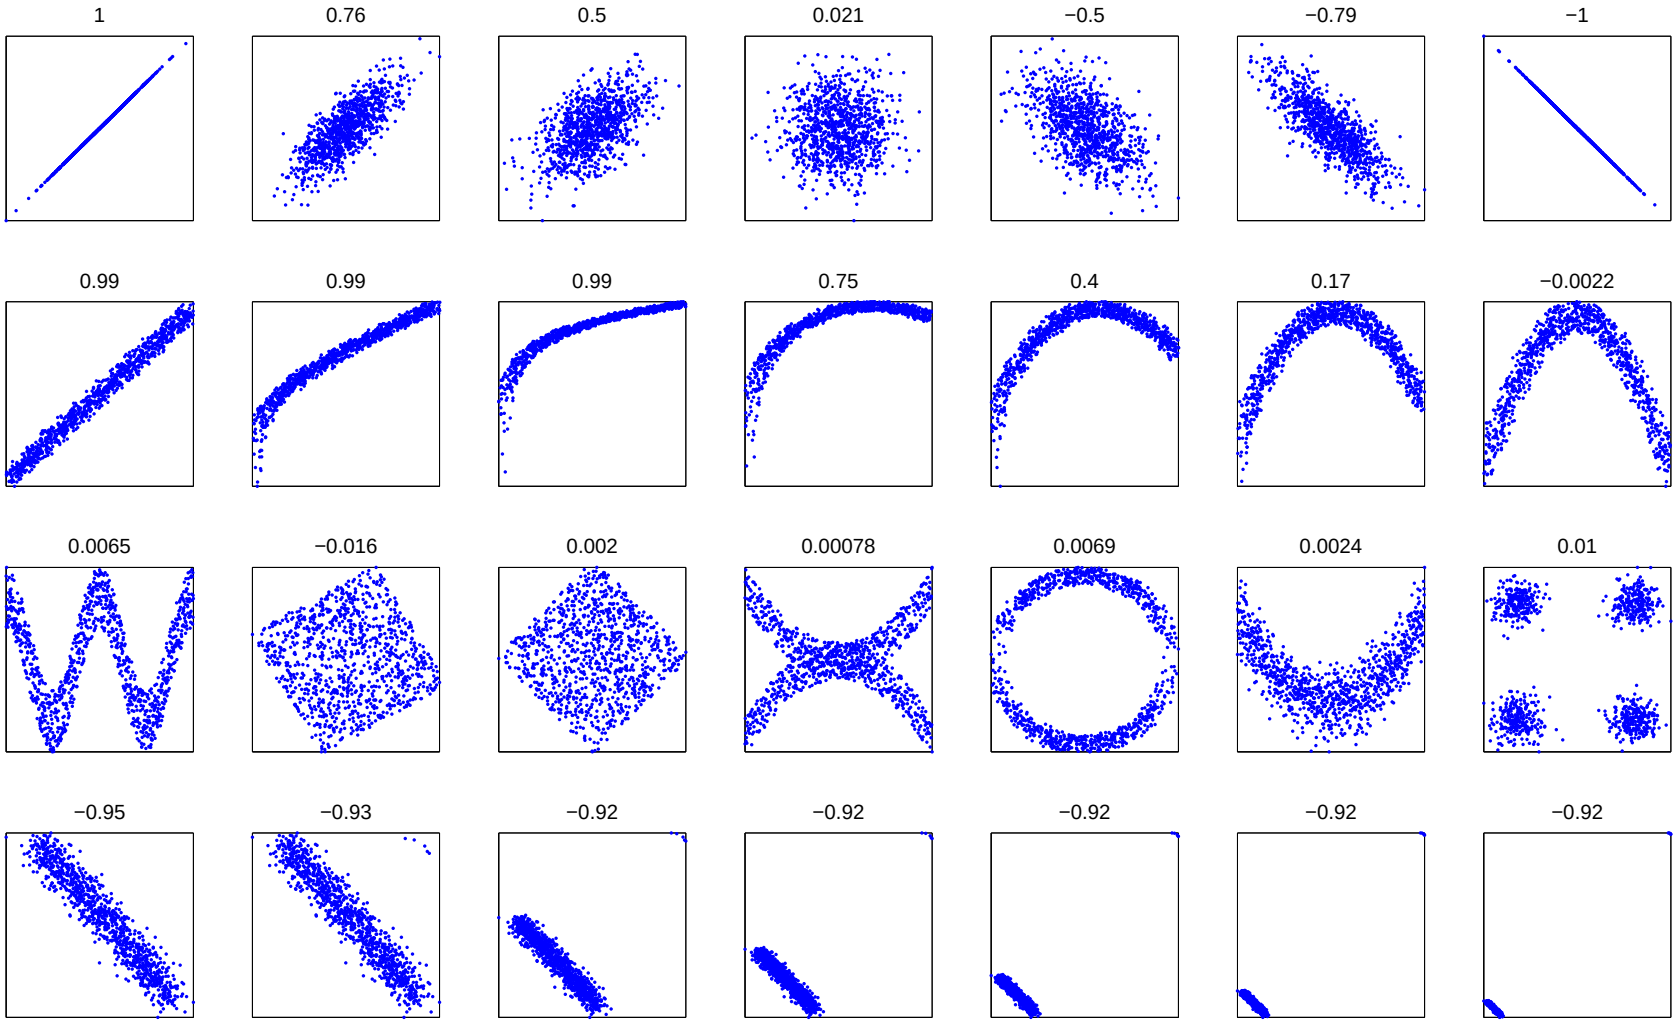

Критерий Стьюдента

выборки: $X_1^n = (X_{11}, \ldots, X_{1n})$,
$X_2^n = (X_{21}, \ldots, X_{2n})$, выборки связанные;

нулевая гипотеза: $H_0 : \rho_{X_1 X_2} = 0$;

альтернатива: $H_1 : \rho_{X_1 X_2} <\neq> 0$;

статистика: $T\left(X_1^n, X_2^n\right) = \frac{\rho_{X_1 X_2}\sqrt{n-2}}{\sqrt{1-\rho^2_{X_1 X_2}}}$;

$T\left(X_1^n, X_2^n\right) \sim St(n-2)$ при H_0.

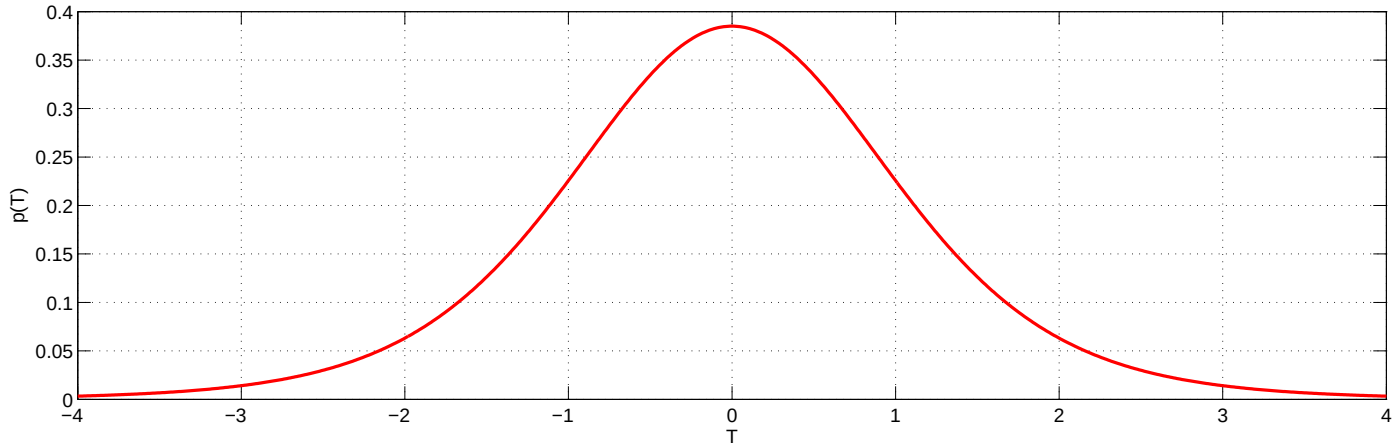

Критерий Стьюдента

Пример (Kanji, критерий 58): выборка из 11 потребителей вегетариантских сосисок оценивает качество двух брендов. Если целевая аудитория двух брендов совпадает, то их рекламу можно давать совместно. Корреляция Спирмена оценок потребителей равна -0.854

$H_0 : \rho_{X_1 X_2} = 0.$
$H_1 : \rho_{X_1 X_2} \neq 0 \Rightarrow p = 0.0024.$

Корреляция Кендалла

Коэффициент корреляции Кендалла $\rho_{X_1X_2}$ случайных величин X_1 и X_2 — мера их взаимной неупорядоченности; также оценивает силу **монотонной** корреляции между величинами.

Выборочный коэффициент корреляции Кендалла:

$$\tau_{X_1X_2} = 1 - \frac{4}{n\,(n-1)} \sum_{i=1}^{n-1} \sum_{j=1}^{n} [[X_{1i} < X_{1j}] \neq [X_{2i} < X_{2j}]] = \frac{C-D}{C+D},$$

где C — число согласованных пар, D — число несогласованных пар.

Корреляция Кендалла

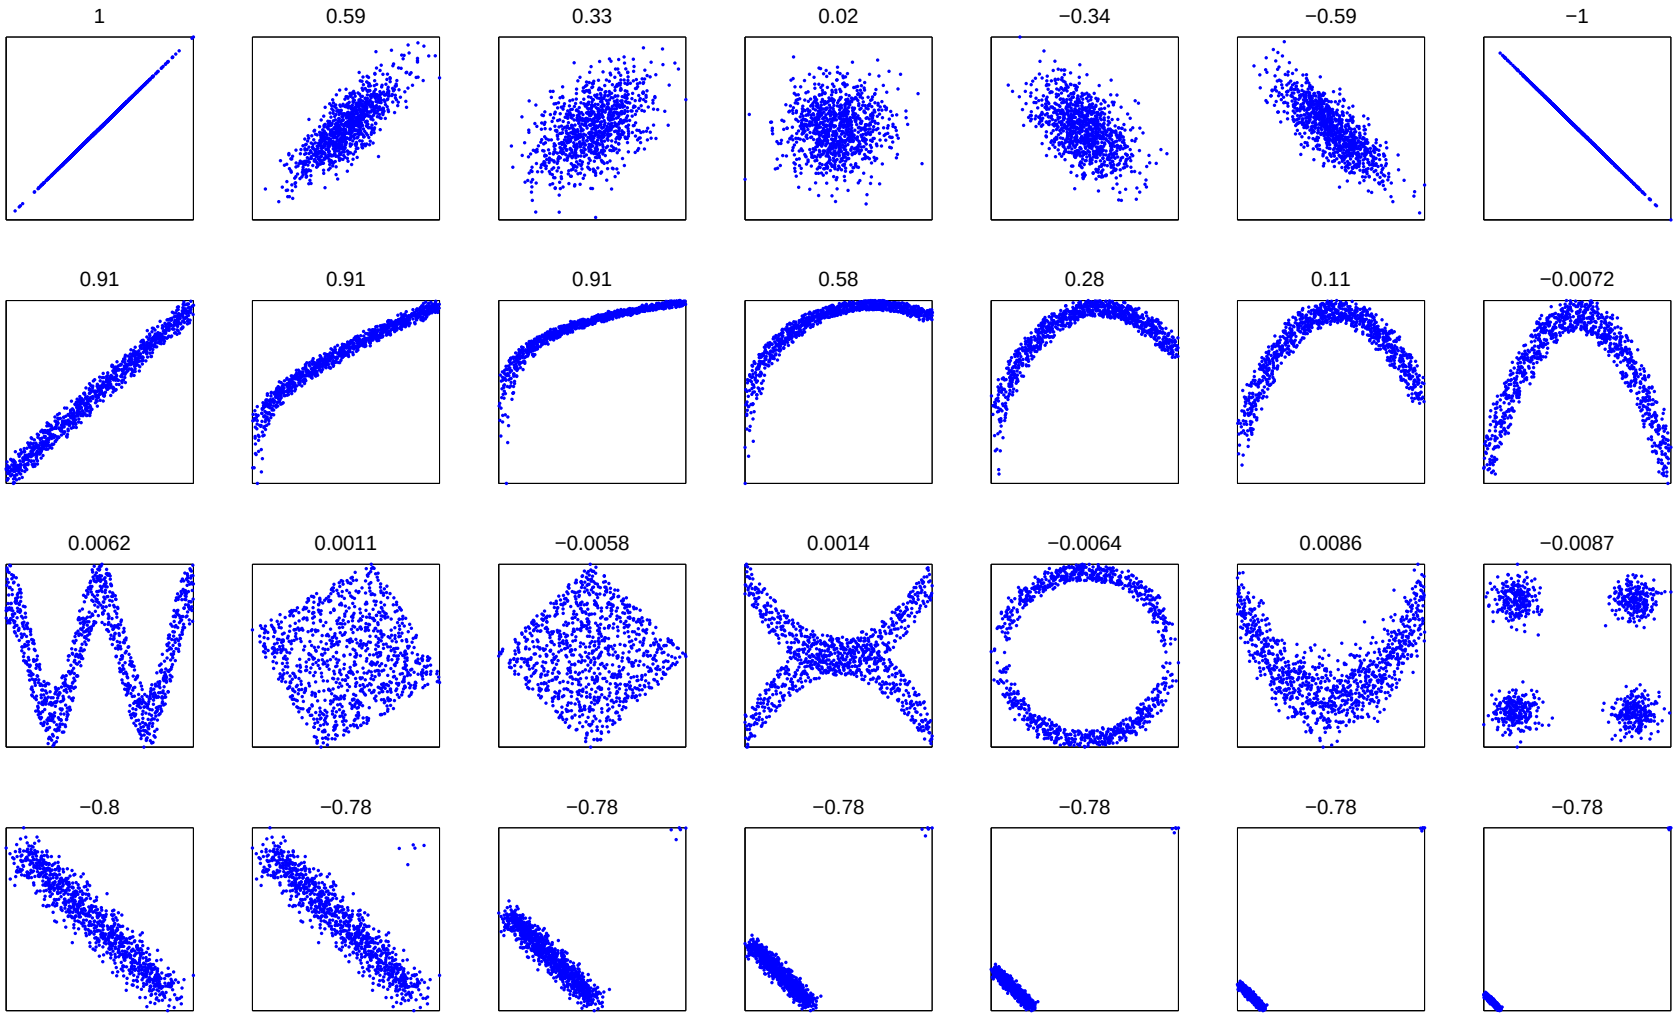

Критерий без названия

выборки: $X_1^n = (X_{11}, \ldots, X_{1n})$,
$X_2^n = (X_{21}, \ldots, X_{2n})$, выборки связанные;
нулевая гипотеза: $H_0 : \tau_{X_1 X_2} = 0$;
альтернатива: $H_1 : \tau_{X_1 X_2} <\neq> 0$;
статистика: $\tau_{X_1 X_2}$ имеет табличное распределение при H_0.

При справедливости H_0

$$\mathbb{E}\tau_{X_1 X_2} = 0, \quad \mathbb{D}\tau_{X_1 X_2} = \frac{2\,(2n+5)}{9n\,(n-1)}.$$

Для $n > 10$ справедлива аппроксимация нормальным распределением.

Критерий без названия

Пример (Kanji, критерий 59): налоговый инспектор хочет проверить наличие взаимосвязи между величинами общего дохода от инвестиций и общего объёма дополнительных доходов. На выборке из 10 налоговых деклараций он получил $D = 5,\ C = 38,\ \tau_{X_1X_2} = 0.7821$.

$H_0 : \tau_{X_1X_2} = 0.$
$H_1 : \tau_{X_1X_2} \neq 0 \Rightarrow p = 0.0027.$

Связь между коэффициентами корреляции

При справедливости H_0 (отсутствии монотонной зависимости):

$$r_{\rho_{X_1X_2}\tau_{X_1X_2}} = \frac{2n+2}{\sqrt{4n^2+10n}}$$

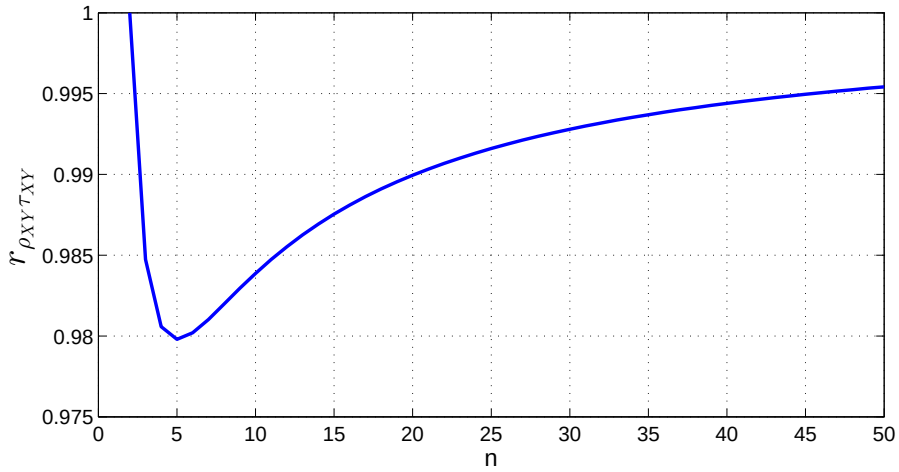

`http://youtu.be/D56dvoVrBBE`: по сравнению с корреляцией Спирмена, корреляция Кендалла

- менее чувствительна к большим различиям между рангами наблюдений;
- точнее оценивается по выборке небольших объёмов;
- обычно меньше по модулю.

$$(X_1, X_2) \sim N(\mu, \Sigma) \quad \Rightarrow \quad \lim_{n\to\infty} \mathbb{E}\tau_{X_1X_2} = \lim_{n\to\infty} \mathbb{E}\rho_{X_1X_2} = \frac{2}{\pi}\arcsin r_{X_1X_2}.$$

Частная корреляция

Если мы подозреваем, что наблюдаемая линейная взаимосвязь между признаками X_1 и X_2 вызвана влиянием третьего признака X_3, можно попытаться его снять.
Частная корреляция:

$$r_{X_1X_2|X_3} = \frac{r_{X_1X_2} - r_{X_1X_3}r_{X_2X_3}}{\sqrt{\left(1 - r^2_{X_1X_3}\right)\left(1 - r^2_{X_2X_3}\right)}}.$$

Если нужно снять влияние нескольких признаков, можно пользоваться рекуррентной формулой:

$$r_{X_1X_2|X_3X_4} = \frac{r_{X_1X_2|X_4} - r_{X_1X_3|X_4}r_{X_2X_3|X_4}}{\sqrt{\left(1 - r^2_{X_1X_3|X_4}\right)\left(1 - r^2_{X_2X_3|X_4}\right)}}.$$

Другой вариант: если M — множество признаков, Ω — обратимая матрица их выборочных корреляций, $R = \Omega^{-1}$, то

$$r_{X_iX_j|M\setminus\{X_i,X_j\}} = -\frac{r_{ij}}{\sqrt{r_{ii}r_{jj}}}.$$

Критерий Стьюдента

выборки: $X_1^n = (X_{11}, \ldots, X_{1n}), X_2^n = (X_{21}, \ldots, X_{2n}),$
$X_3^n = (X_{31}, \ldots, X_{3n}), X_3 \in \mathbb{R}^M,$
$(X_1, X_2, X_3) \sim N(\mu, \Sigma);$

нулевая гипотеза: $H_0 : r_{X_1 X_2 | X_3} = 0;$

альтернатива: $H_1 : r_{X_1 X_2 | X_3} <\neq> 0;$

статистика: $T(X_1^n, X_2^n, X_3^n) = \frac{r_{X_1 X_2 | X_3} \sqrt{n-M-2}}{\sqrt{1-r^2_{X_1 X_2 | X_3}}};$

$T(X_1^n, X_2^n, X_3^n) \sim St(n-M-2)$ при H_0.

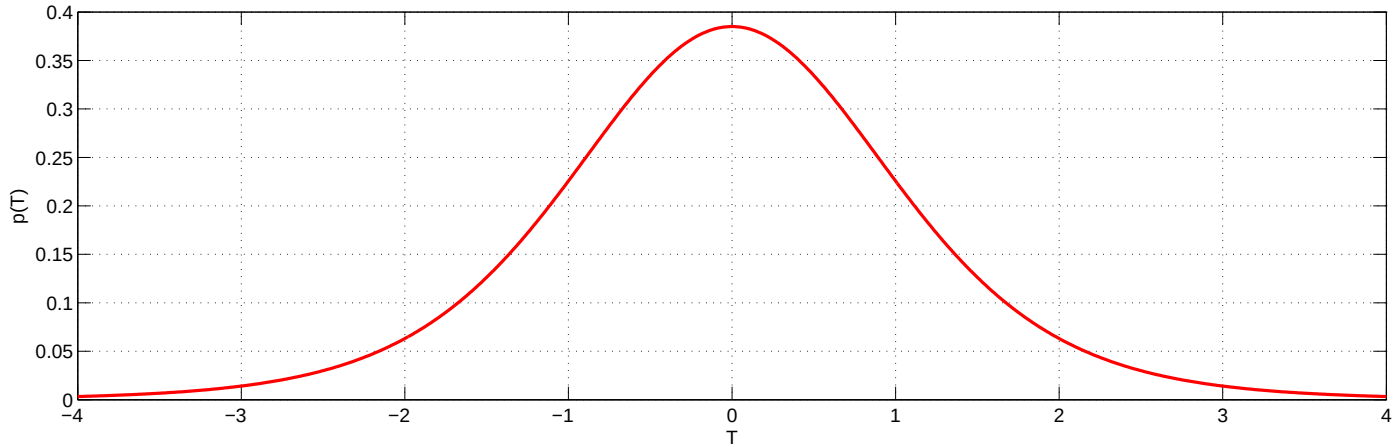

Множественная корреляция

Для того, чтобы оценить силу линейной взаимосвязи одной переменной (X_1) с несколькими другими (X_2, X_3), используется множественная корреляция:

$$r_{X_1,X_2,X_3} = \frac{r^2_{X_1X_2} + r^2_{X_1X_3} - 2r_{X_1X_2}r_{X_1X_3}r_{X_2X_3}}{1 - r^2_{X_2X_3}}.$$

Для большего числа признаков: пусть M — множество дополнительных признаков, Ω — обратимая матрица их выборочных корреляций, $R = \Omega^{-1}$, c — вектор корреляций основного признака X с дополнительными; тогда

$$r^2_{X,M} = c^T Rc.$$

Находится такая линейная комбинация признаков из M, что корреляция X с ней максимальна.

$r_{X,M} \in [0, 1]$.

Критерий Фишера

выборки: $X_1^n = (X_{11}, \ldots, X_{1n})$,
$X_2^n = (X_{21}, \ldots, X_{2n}), X_2 \in \mathbb{R}^M$,
$(X_1, X_2) \sim N(\mu, \Sigma)$;

нулевая гипотеза: $H_0 : r_{X_1,X_2} = 0$;

альтернатива: $H_1 : r_{X_1,X_2} > 0$;

статистика: $F(X_1^n, X_2^n) = \frac{r^2_{X_1,X_2}}{1-r^2_{X_1,X_2}} \frac{n-M-1}{M-2}$;

$F(X_1^n, X_2^n) \sim F(M-2, n-M-1)$ при H_0.

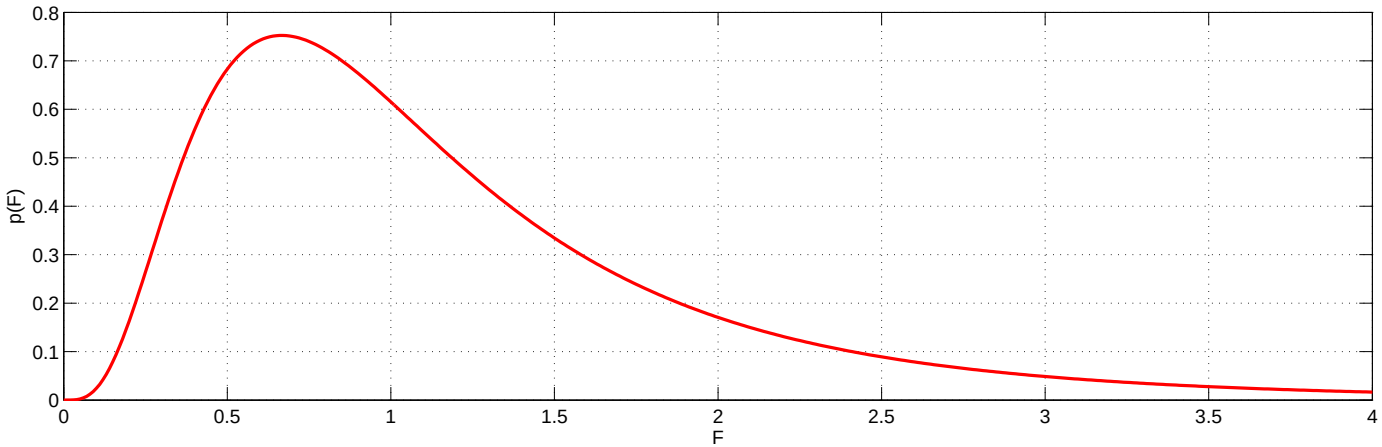

Температура воздуха и географическое положение

По 56 городам США известны средняя минимальная температура января и географические координаты (широта, долгота). Требуется исследовать характер зависимости между переменными.

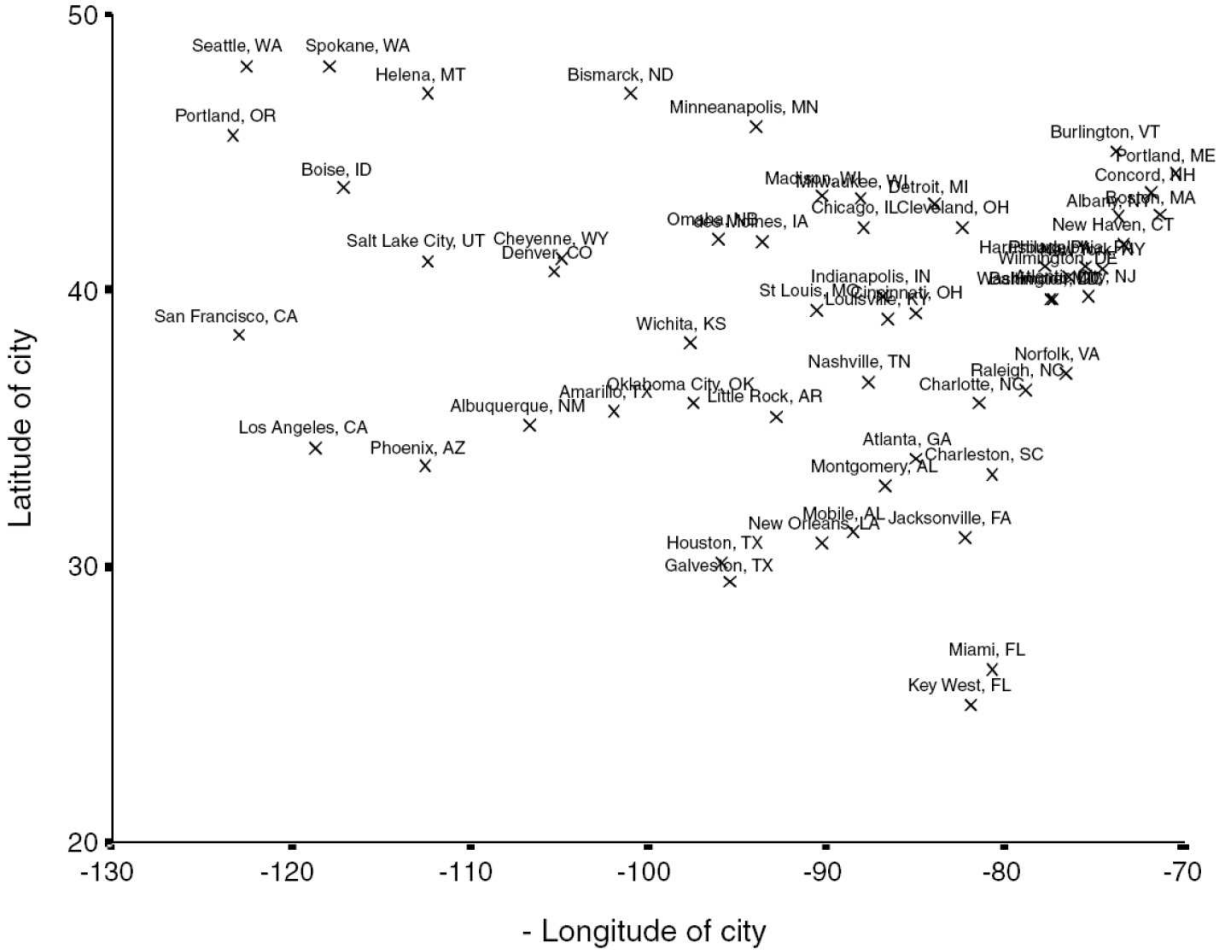

Температура воздуха и географическое положение

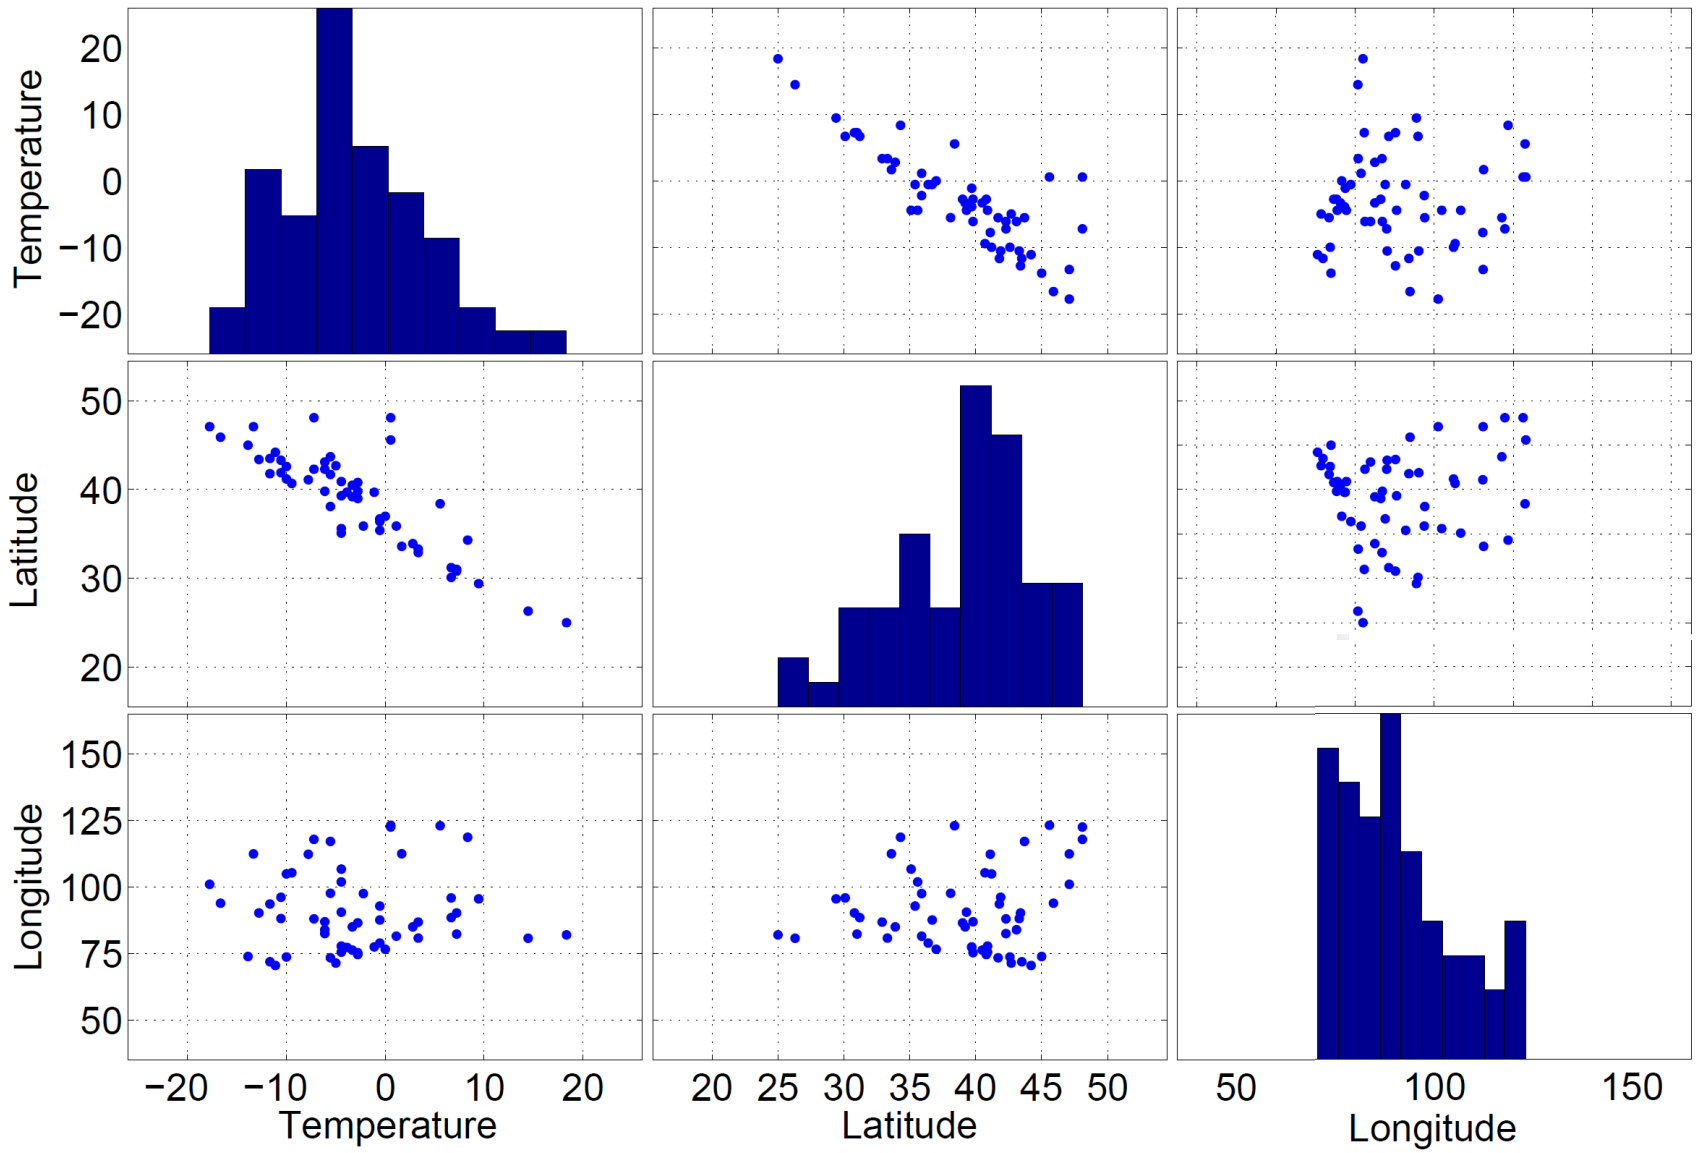

Температура воздуха и географическое положение

T — температура, λ — долгота, ϕ — широта;
r — корреляция Пирсона, ρ — Спирмена, τ — Кендалла.

Коэффициенты корреляции:

r	T	ϕ	λ
T	–	**−0.848**	0.024
ϕ	**−0.848**	–	0.145
λ	0.024	0.145	–

τ	T	ϕ	λ
T	–	**−0.683**	0.030
ϕ	**−0.683**	–	−0.011
λ	0.030	−0.011	–

ρ	T	ϕ	λ
T	–	**−0.815**	0.030
ϕ	**−0.815**	–	0.023
λ	0.030	0.023	–

Достигаемые уровни значимости:

r	T	ϕ	λ
T	–	**0.000**	0.861
ϕ	**0.000**	–	0.287
λ	0.861	0.287	–

τ	T	ϕ	λ
T	–	**0.000**	0.756
ϕ	**0.000**	–	0.910
λ	0.756	0.910	–

ρ	T	ϕ	λ
T	–	**0.000**	0.829
ϕ	**0.000**	–	0.865
λ	0.829	0.865	–

Температура воздуха и географическое положение

T — температура, λ — долгота, ϕ — широта;
r — частная корреляция Пирсона, ρ — Спирмена.

Коэффициенты частной корреляции:

r	T	ϕ	λ
T	–	**−0.861**	**0.280**
ϕ	**−0.861**	–	**0.312**
λ	**0.280**	**0.312**	–

ρ	T	ϕ	λ
T	–	**−0.817**	0.084
ϕ	**−0.817**	–	0.082
λ	0.084	0.082	–

Достигаемые уровни значимости:

r	T	ϕ	λ
T	–	**0.000**	**0.039**
ϕ	**0.000**	–	**0.021**
λ	**0.039**	**0.021**	–

ρ	T	ϕ	λ
T	–	**0.000**	0.543
ϕ	**0.000**	–	0.552
λ	0.543	0.552	–

Температура воздуха и географическое положение

T — температура, λ — долгота, ϕ — широта;
R — множественная корреляция.

Коэффициенты множественной корреляции:

	T	ϕ	λ
R	0.659	0.667	0.312
p	6.0347×10^{-8}	3.6481×10^{-8}	0.0216
with	$0.235 \cdot \lambda - 0.638 \cdot \phi$	$0.397 \cdot \lambda - 0.678 \cdot T$	$1.542 \cdot T + 2.450 \cdot \phi$

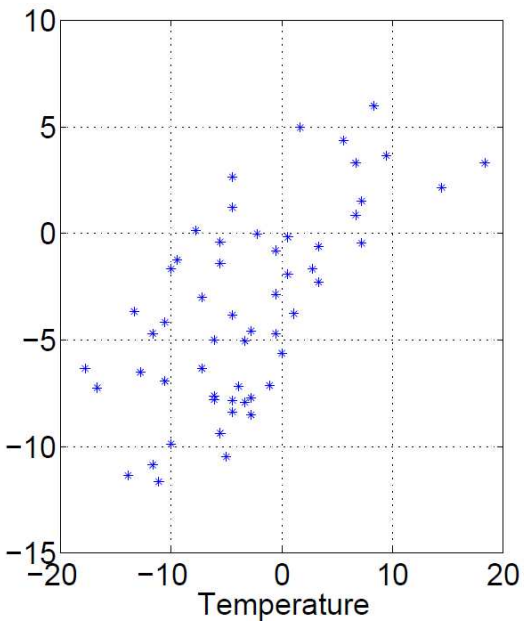

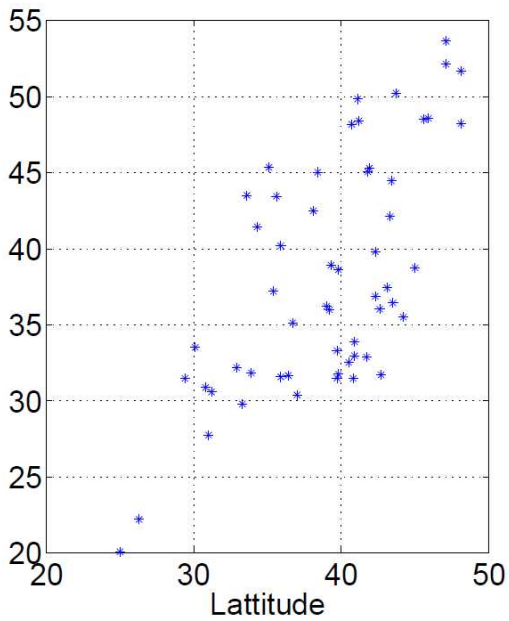

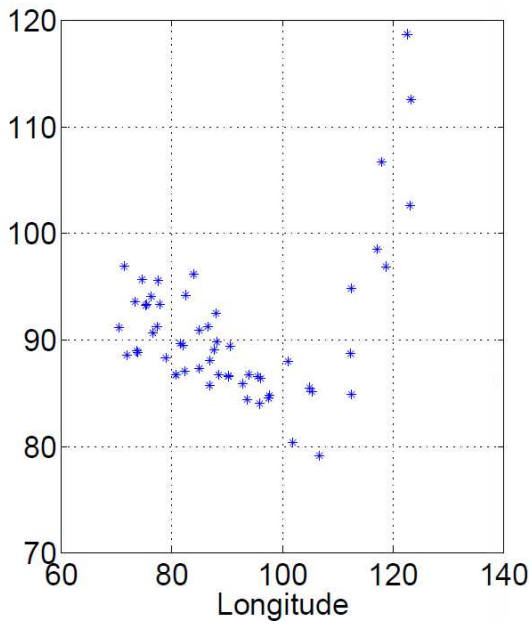

Канонические корреляции

Для того, чтобы оценить силу линейных взаимосвязей между двумя множествами переменных, используется метод канонических корреляций.

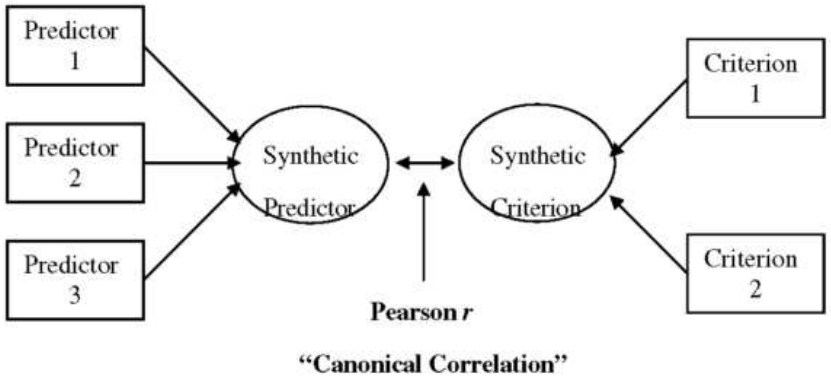

Метод находит пары линейных комбинаций переменных, имеющие максимальную корреляцию Пирсона; элементы каждой следующей пары ортогональны всем элементам предыдущих.
Канонические корреляции на множествах признаков X и Y — квадраты собственных значений матрицы

$$R = R_{YY}^{-1} R_{YX} R_{XX}^{-1} R_{XY}.$$

Не все $\min(|X|, |Y|)$ канонических пар значимы и интерпретируемы.

Критерий хи-квадрат

выборки: $X^n \in \mathbb{R}^{n \times k_x} \sim N(\mu_x, \Sigma_x)$, $Y^n \in \mathbb{R}^{n \times k_y} \sim N(\mu_y, \Sigma_y)$,
$k = \min(k_x, k_y)$, $r_c^m = \{r_c^m, \ldots, r_c^k\}$;

нулевая гипотеза: $H_0 : r_c^m = \cdots = r_c^k = 0$;

альтернатива: $H_1 : H_0$ неверна;

статистика: $\chi^2(X^n, Y^n) = -\left(n - 1 - \frac{k_x + k_y + 1}{2}\right) \ln \Lambda_m$,

$$\Lambda_m = \prod_{i=m}^{k} \left(1 - \left(r_c^i\right)^2\right),$$

$\chi^2(X^n, Y^n) \sim \chi^2_{(k_x - m + 1)(k_y - m + 1)}$ при H_0.

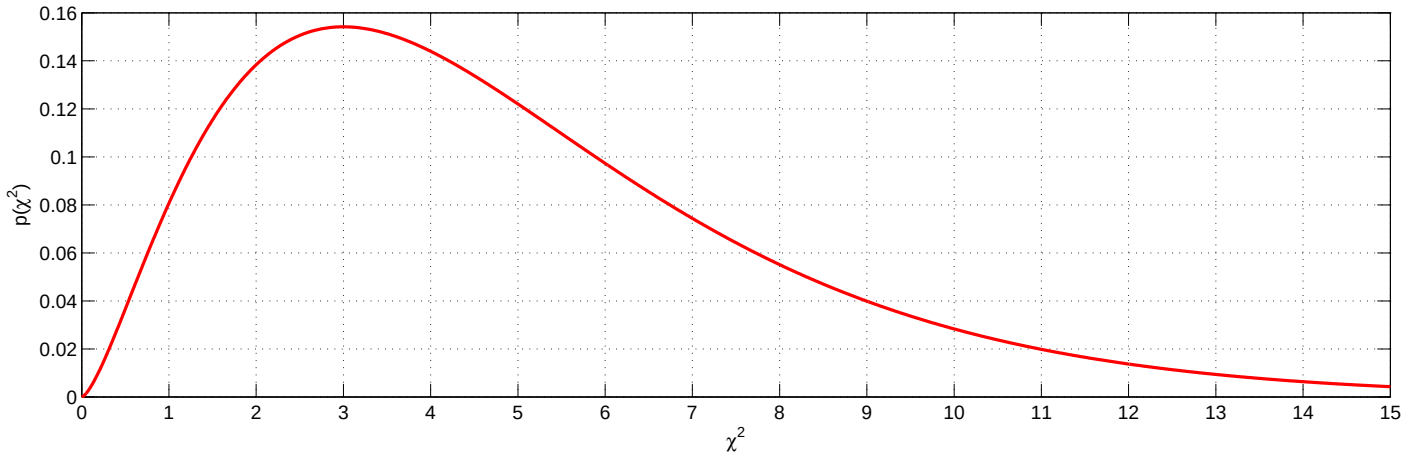

Вспомогательные статистики

- structure coefficients/loadings — структурные коэффициенты — корреляции Пирсона исходных признаков с каноническими комбинациями;
- communality — относительная дисперсия факторов в значимых канонических комбинациях — суммы квадратов структурных коэффициентов каждого фактора по всем значимым каноническим комбинациям;
- adequacy — средняя доля дисперсии «своего» множества, объяснённой канонической комбинацией — средние квадраты структурных коэффициентов всех факторов в канонических комбинациях;
- redundancy — средняя доля дисперсии «чужого» множества, объяснённой канонической комбинацией — произведение adequacy и квадрата канонической корреляции.

Пример

Успеваемость и личные качества первокурсников:
`https://yadi.sk/d/pBLtuerxf8tBM`

Таблица сопряжённости $K_1 \times K_2$

Имеются связанные выборки $X_1^n = (X_{11}, \ldots, X_{1n})$ и $X_2^n = (X_{21}, \ldots, X_{2n})$, $X_1 \in \{1, \ldots, K_1\}$, $X_2 \in \{1, \ldots, K_2\}$.

Таблица сопряжённости:

X_1 \ X_2	1	$\ldots$	j	$\ldots$	K_2	$\sum$
1						
$\vdots$						
i			n_{ij}			n_{i+}
$\vdots$						
K_1						
$\sum$			n_{+j}			n

Два случайных признака

Пусть π_{ij} — вероятность реализации пары (X_1, X_2) в ячейке (i, j).
$\{\pi_{ij}\}$ — совместное распределение (X_1, X_2);
$\{\pi_{i+}\}, \{\pi_{+j}\}$ — маргинальные распределения.

X_1 и X_2 независимы, если

$$\pi_{ij} = \pi_{i+}\pi_{+j} \quad \forall i = 1, \ldots, K_1, j = 1, \ldots, K_2.$$

Один случайный признак

Пусть X_1 — не случайная величина, а фиксированный признак. Тогда $\{\pi_{ij}\}$ не имеет смысла, вместо него рассматриваются $\{\pi_{1|i}, \ldots, \pi_{K_1|i}\}$ — условные распределения X_2 при $X_1 = i$.

X_1 и X_2 независимы, если

$$\pi_{j|1} = \cdots = \pi_{j|K_1} \quad \forall j = 1, \ldots, K_2.$$

Порождающие модели

1. Если все ячейки таблицы случайны, то распределение n_{ij} может быть, например, пуассоновским со средними μ_{ij}; совместная функция вероятности таблицы:
$$\prod_i \prod_j \frac{e^{-\mu_{ij}} \mu_{ij}^{n_{ij}}}{n_{ij}!}.$$
2. Если суммарный объём выборки n фиксирован, данные описываются мультиномиальной моделью:
$$\frac{n!}{n_{11}! \cdot \ldots \cdot n_{K_1 K_2}!} \prod_i \prod_j \pi_{ij}^{n_{ij}}.$$
3. Если X_1 не случайна, то фиксированы суммы по строкам n_{i+}, и каждая строка i порождается отдельной мультиномиальной моделью:
$$\frac{n_{i+}!}{\prod_j n_{ij}!} \prod_j \pi_{i|j}^{n_{ij}}.$$

Порождающие модели

Исследование: как исход автомобильной аварии на заданной магистрали X_1 (смертельный, несмертельный) зависит от использования ремня безопасности X_2 (был использован, не был использован)?

Исход \ Ремень	использован	не использован
смертельный		
несмертельный		

1. Исследователи собираются учесть все автомобильные аварии, которые произойдут на магистрали в течение года.
2. Исследователи запросят 200 случайных полицейских рапортов об авариях за последние годы.
3. Исследователи запросят 200 случайных полицейских рапортов об авариях за последние годы: 100 об авариях со смертельным исходом и 100 об авариях без смертельного исхода.

Таблица сопряжённости 2×2

Пусть X_1 и X_2 принимают значения 0 и 1.

X_1 \ X_2	0	1	$\sum$
0	a	b	$a+b$
1	c	d	$c+d$
$\sum$	$a+c$	$b+d$	n

Критерий хи-квадрат

выборки: $X_1^n = (X_{11}, \ldots, X_{1n}), \quad X_1 \in \{1, \ldots, K_1\},$
$X_2^n = (X_{21}, \ldots, X_{2n}), \quad X_2 \in \{1, \ldots, K_2\},$
выборки связанные;

нулевая гипотеза: H_0: X_1 и X_2 независимы;

альтернатива: H_1: H_0 неверна;

статистика: $$\chi^2\left(X_1^n, X_2^n\right) = \sum_{i=1}^{K_1}\sum_{j=1}^{K_2} \frac{\left(n_{ij} - \frac{n_{i+}n_{+j}}{n}\right)^2}{\frac{n_{i+}n_{+j}}{n}} = n\left(\sum_{i=1}^{K_1}\sum_{j=1}^{K_2} \frac{n_{ij}^2}{n_{i+}n_{+j}} - 1\right);$$

$$\chi^2\left(X_1^n, X_2^n\right) \sim \chi^2_{(K_1-1)(K_2-1)} \text{ при } H_0.$$

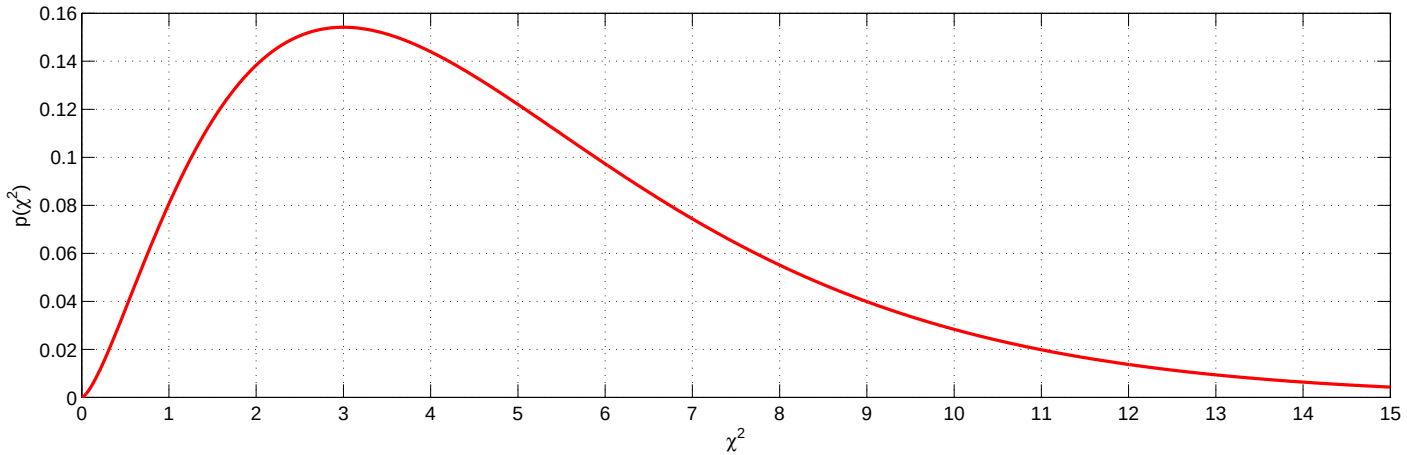

Условия применимости критерия:

- $n \geq 40$;
- $\frac{n_{i+}n_{+j}}{n} < 5$ не более, чем в 20% ячеек.

Критерий хи-квадрат

Пример: исследуется влияние препарата на некоторое заболевание. Часть испытуемых принимает препарат, часть — плацебо; по окончании курса определяется, произошло ли выздоровление.

	Выздоровели	Нет
Препарат	850	870
Плацебо	380	410

H_0: препарат неотличим от плацебо.
H_1: эффект препарата отличается от эффекта плацебо $\Rightarrow p = 0.5398$.

G-критерий

выборки: $X_1^n = (X_{11}, \ldots, X_{1n}), \quad X_1 \in \{1, \ldots, K_1\},$
$X_2^n = (X_{21}, \ldots, X_{2n}), \quad X_2 \in \{1, \ldots, K_2\},$
выборки связанные;

нулевая гипотеза: H_0: X_1 и X_2 независимы

альтернатива: H_1: H_0 неверна;

статистика: $G^2\left(X_1^n, X_2^n\right) = 2 \sum_{i=1}^{K_1} \sum_{j=1}^{K_2} n_{ij} \ln \frac{n_{ij} n}{n_{i+} n_{+j}};$

$G^2\left(X_1^n, X_2^n\right) \sim \chi^2_{(K_1-1)(K_2-1)}$ при H_0.

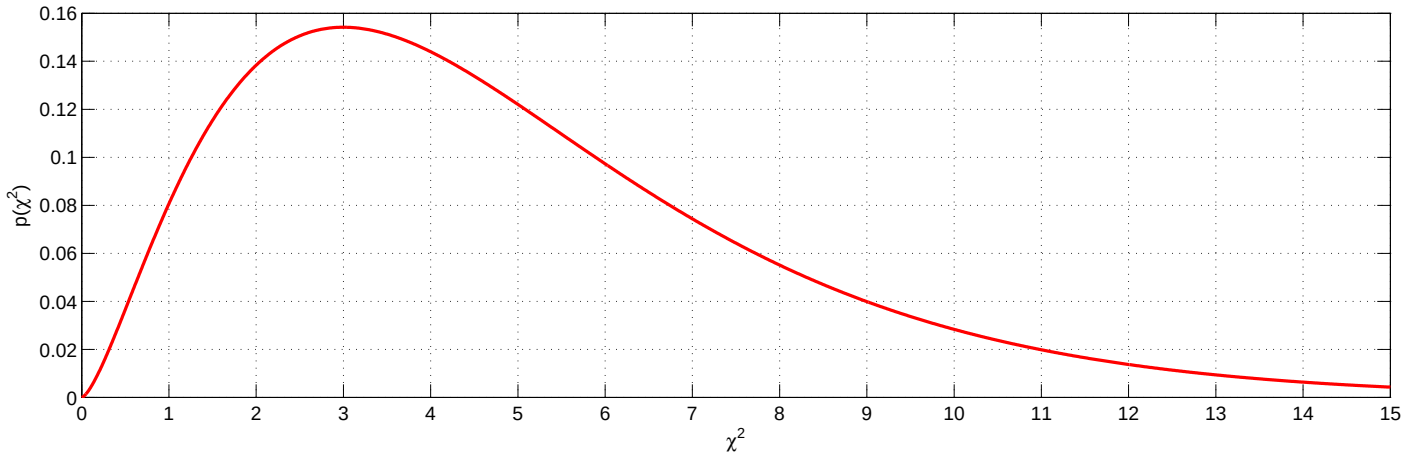

Точный критерий Фишера

выборки: $X_1^n = (X_{11}, \ldots, X_{1n}), X_1 \in \{0, 1\}$,
$X_2^n = (X_{21}, \ldots, X_{2n}), X_2 \in \{0, 1\}$,
выборки связанные;
нулевая гипотеза: H_0: X_1 и X_2 независимы;
альтернатива: H_1: H_0 неверна.

Пусть в таблице сопряжённости суммы по строкам и столбцам фиксированы, тогда вероятность появления наблюдаемой таблицы равна

$$P\left(X_1^n, X_2^n\right) = \frac{(a+b)!\,(c+d)!\,(a+c)!\,(b+d)!}{a!b!c!d!n!}.$$

Достигаемый уровень значимости определяется как сумма по всем возможным вариантам таблицы с такими же суммами по строкам и столбцам, имеющим вероятность не более $P\left(X_1^n, X_2^n\right)$.

Для односторонней альтернативы ($ad \ll bc$) достигаемый уровень значимости можно определить через гипергеометрическое распределение:

$$p = \sum_{i=0}^{a} \frac{C_{a+b}^i C_{c+d}^{a+c-i}}{C_n^{a+c}}.$$

Точный критерий Фишера

Пример: для 26 опрошенных известен пол и сидят ли они на диете. Есть ли связь между этими признаками?

	М	Ж
На диете	1	9
Не на диете	13	3

H_0: связи нет.
H_1: признаки связаны $\Rightarrow p = 0.0014$.

Коэффициент V Крамера

Мера взаимосвязи между двумя категориальными переменными — коэффициент V Крамера:

$$\phi_c\left(X_1^n, X_2^n\right) = \sqrt{\frac{\chi^2\left(X_1^n, X_2^n\right)}{n\left(\min\left(K_1, K_2\right) - 1\right)}}.$$

$\phi_c\left(X_1^n, X_2^n\right) \in [0, 1]$; 0 соответствует полному отсутствию взаимосвязи, 1 — совпадению переменных.

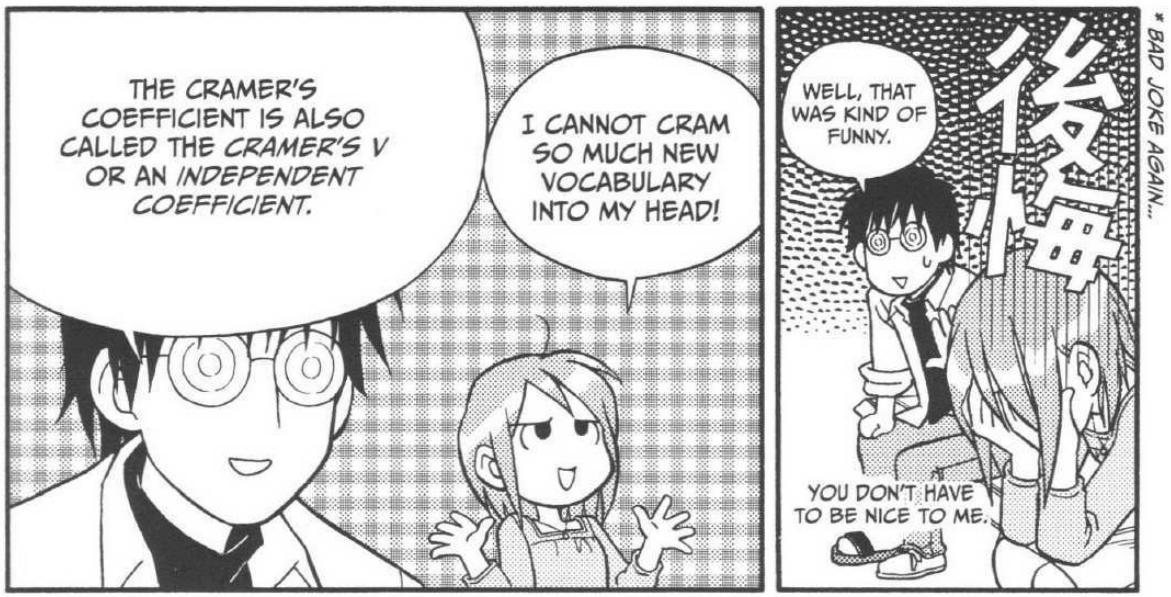

Корреляция между порядковыми переменными

Мера взаимосвязи между двумя порядковыми переменными — коэффициент γ:

$$\hat{\gamma} = \frac{p_C - p_D}{n^2 - p_t},$$

где $p_C = \frac{C}{n}$ — частота появления согласованных пар элементов выборки, т. е., таких, что $i_1 > i_2,\ j_1 > j_2$ или $i_1 < i_2,\ j_1 < j_2$;
$p_D = \frac{D}{n}$ — частота несогласованных пар;
$p_t = \frac{T}{n}$ — частота таких пар, что $i_1 = i_2$ или $j_1 = j_2$.
$\gamma \in [-1, 1]$; -1 соответствует полному отсутствию согласованных пар, 1 — отсутствию несогласованных.

Политические взгляды	Счастье		
	Не слишком счастлив	Вполне счастлив	Очень счастлив
Либеральные	13	29	15
Умеренные	23	59	47
Консервативные	14	67	54

$\chi^2 = 7.07, p = 0.1322, \phi_c = 0.0742$;
$\hat{\gamma} = 0.185,\ 95\%$ доверительный интервал — $[0.032, 0.338]$.

Корреляция Мэтьюса

Мера взаимосвязи между двумя бинарными переменными — коэффициент корреляции Мэтьюса:

$$MCC = \frac{ad - bc}{\sqrt{(a+b)(a+c)(b+d)(c+d)}}.$$

$MCC \in [-1, 1]$; 0 соответствует полному отсутствию взаимосвязи, 1 — нулям на побочной диагонали, -1 — нулям на главной диагонали.

Пример

Религиозность и уровень образования:
`https://yadi.sk/d/yTXbdCtYf8z8t`

Парадокс хи-квадрат (Симпсона)

Эксперимент: пациенты принимают препарат или плацебо, по окончании курса определяется, выздоровели они или нет.
Есть ли связь между выздоровлением и приёмом препарата?

Мужчины	Выздоровели	Нет
Препарат	700	800
Плацебо	80	130

Женщины	Выздоровели	Нет
Препарат	150	70
Плацебо	300	280

Для мужчин: $\chi^2 = 5.456,\ p = 0.0195.$
Для женщин: $\chi^2 = 17.555,\ p = 2.7914 \times 10^{-5}.$

М+Ж	Выздоровели	Нет
Препарат	850	870
Плацебо	380	410

Суммарно: $\chi^2 = 0.376,\ p = 0.5398.$

Парадокс хи-квадрат (Симпсона)

Причины несогласованности выводов — большие отличия в размерах групп пациентов, принимающих плацебо и препарат: основной вклад в выводы вносят женщины, принимавшие плацебо, и мужчины, принимавшие препарат.

Чтобы такого не происходило, плацебо и препарат должны поровну распределяться по всем анализируемым подгруппам.

Парадокс хи-квадрат (Симпсона)

Пример (Bikel at el., 1975): в 1973 году на университет Беркли, Калифорния, подали в суд: доля поступивших абитуриентов мужского пола была выше, чем доля поступивших женского пола.

	Не поступили	Поступили	Доля поступивших
Мужчины	4704	3738	44.3%
Женщины	2827	1494	34.6%

Парадокс хи-квадрат (Симпсона)

Критерий хи-квадрат: $\chi^2 = 108.1,\ p \approx 0.$

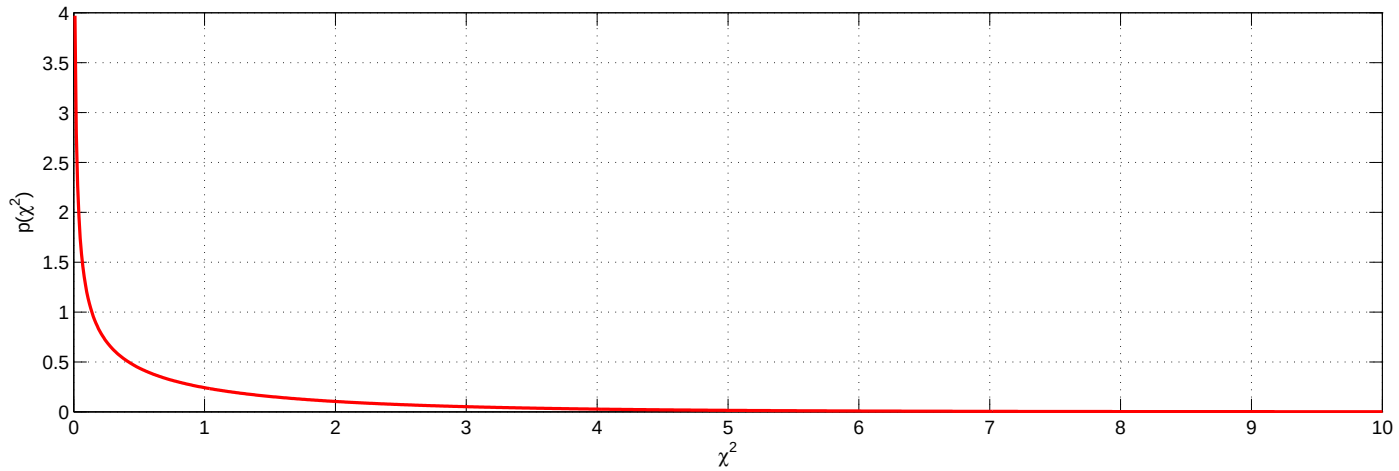

	Наблюдаемые		Ожидаемые		Разности	
	-	+	-	+	-	+
Мужчины	4704	3738	4981.3	3460.7	-227.3	227.3
Женщины	2827	1494	2549.7	1771.3	227.3	-227.3

Парадокс хи-квадрат (Симпсона)

Будем искать виноватых: посмотрим детализированную статистику по 85 факультетам.

Значимо (при $\alpha = 0.05$) меньше женщин прошли отбор на 4 факультета, суммарный дефицит по ним — 26.
На 6 факультетов поступило значимо меньше мужчин, суммарный дефицит — 64.

Данные по 6 крупнейшим факультетам:

	Мужчины		Женщины	
	$\sum$	+	$\sum$	+
1	825	62%	108	**82%**
2	560	63%	25	**68%**
3	325	**37%**	593	34%
4	417	33%	375	**35%**
5	191	**28%**	393	24%
6	272	6%	341	**7%**

Парадокс хи-квадрат (Симпсона)

Ответ: женщины чаще пытались поступить на факультеты с большим конкурсом.

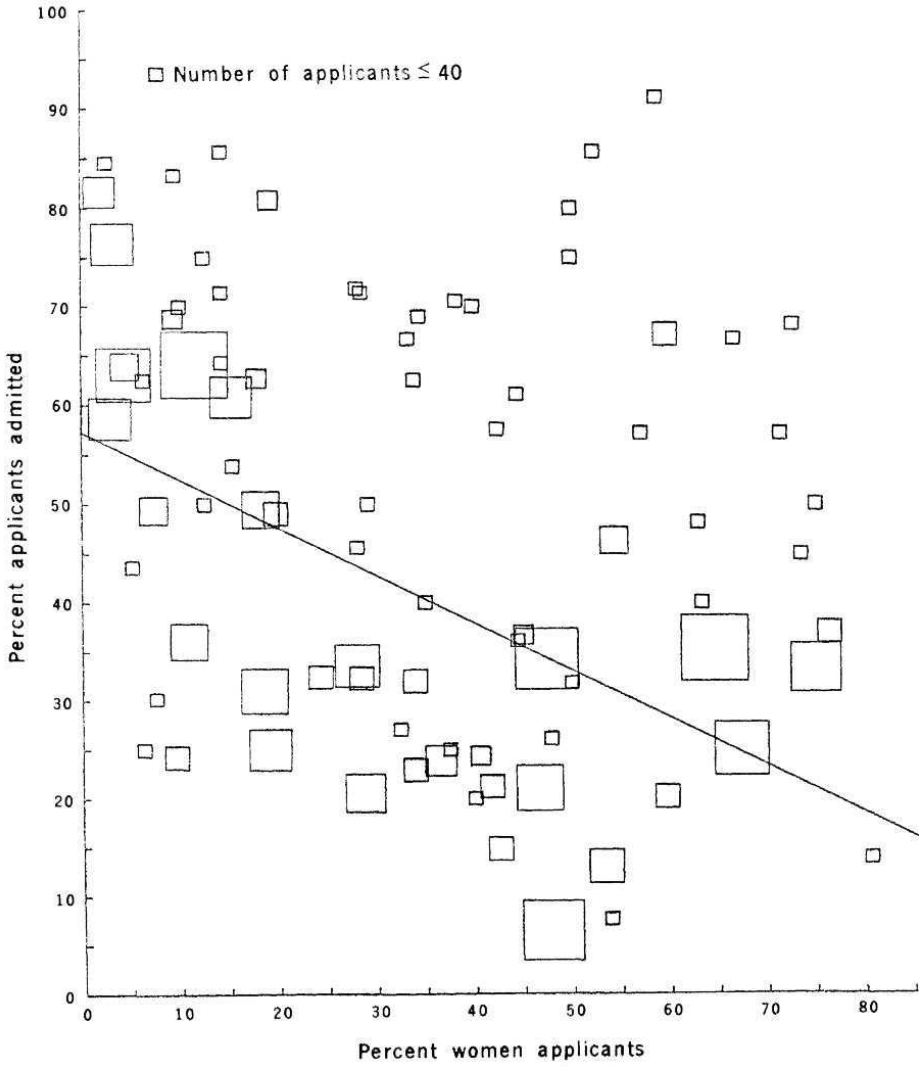

Парадокс хи-квадрат (Симпсона)

"Like fire, the chi-square statistic is an excellent servant and a bad master."
(Austin Bradford Hill)

Литература

- непрерывные признаки — Лагутин, гл. 20;
- категориальные признаки — Agresti, гл. 2 и 3;
- значимость корреляции Пирсона — Kanji, №12, Good, 3.8;
- значимость корреляции Кендалла и Спирмена — Кобзарь, 5.2.2.2.1, 5.2.2.2.2;
- значимость частной и множественной корреляций — Кобзарь, 5.2.1.3;
- канонические корреляции — Tabachnick, гл. 12.

Кобзарь А.И. *Прикладная математическая статистика*. — Москва: Физматлит, 2006.

Лагутин М.Б. *Наглядная математическая статистика*. — Москва: Бином, 2007.

Agresti A. *Categorical Data Analysis*. — Hoboken: Wiley, 2013.

Bickel P.J., Hammel E.A., O'connell J.W. (1975). *Sex bias in graduate admissions: data from Berkeley*. Science (New York, N.Y.), 187(4175), 398–404.

Good P. *Permutation, Parametric and Bootstrap Tests of Hypotheses: A Practical Guide to Resampling Methods for Testing Hypotheses*. — New York: Springer, 2005.

Kanji G.K. *100 statistical tests*. — London: SAGE Publications, 2006.

Tabachnick B.G., Fidell L.S. *Using Multivariate Statistics*. — Boston: Pearson Education, 2012.