

Прикладная статистика 6. Анализ зависимостей.

11 октября 2013 г.

Задача исследования взаимосвязи между признаками

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


Насколько сильно признаки X_1, X_2 связаны между собой?

Статистическая взаимосвязь между случайными величинами —
корреляция.


Корреляция и причинность

Корреляция — мера ассоциативной связи (одновременная встречаемость событий, сходство паттернов).

Никакого отношения к причинно-следственной связи она не имеет!



Пример:



Статистика не занимается и не имеет средств для того, чтобы заниматься причинно-следственными связями.

Корреляция Пирсона

Корреляция Пирсона (Pearson product-moment correlation coefficient):


$$r_{XY} = \frac{\text{cov}(X_1, X_2)}{\sqrt{\mathbb{D}X_1 \mathbb{D}X_2}} = \frac{\mathbb{E}((X_1 - \mathbb{E}X_1)(X_2 - \mathbb{E}X_2))}{\sqrt{\mathbb{D}X_1 \mathbb{D}X_2}}.$$

Выборочный коэффициент корреляции Пирсона:

$$r_{X_1 X_2} = \frac{\sum_{i=1}^n (X_{1i} - \bar{X}_1)(X_{2i} - \bar{X}_2)}{\sqrt{\sum_{i=1}^n (X_{1i} - \bar{X}_1)^2 \sum_{i=1}^n (X_{2i} - \bar{X}_2)^2}}.$$

$r_{X_1 X_2} \in [-1, 1]$ — мера **линейной** связи.

Корреляция Пирсона



Критерий Стьюдента


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

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 ;



достигаемый уровень значимости:

$$p(t) = \begin{cases} 1 - tcdf(t, n-2), & H_1: r_{X_1 X_2} > 0, \\ tcdf(t, n-2), & H_1: r_{X_1 X_2} < 0, \\ 2(1 - tcdf(|t|, n-2)), & H_1: r_{X_1 X_2} \neq 0. \end{cases}$$

Критерий Стьюдента

Доверительный интервал для коэффициента корреляции Пирсона:

$$\left[r_{X_1 X_2} + \frac{t_{n-2, \alpha/2} (1 - r_{X_1 X_2}^2)}{\sqrt{n}}, r_{X_1 X_2} - \frac{t_{n-2, \alpha/2} (1 - r_{X_1 X_2}^2)}{\sqrt{n}} \right].$$

С использованием преобразования Фишера:

$$\left[\tanh \left(\operatorname{arctanh} r_{X_1 X_2} + \frac{z_{\alpha/2}}{\sqrt{n-3}} \right), \tanh \left(\operatorname{arctanh} r_{X_1 X_2} - \frac{z_{\alpha/2}}{\sqrt{n-3}} \right) \right].$$

Критерий Стьюдента

Пример: 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: $X_1^n = (X_{11}, \dots, X_{1n}),$ $X_2^n = (X_{21}, \dots, X_{2n}),$ выборки связанные;нулевая гипотеза: $H_0: r_{X_1 X_2} = 0;$ альтернатива: $H_1: r_{X_1 X_2} < \neq > 0;$ статистика: $T(X_1^n, X_2^n) = r_{X_1 X_2}.$ Нулевое распределение $T(X_1^n, X_2^n)$ порождается группой перестановок

$$G = \{g: gX_2^n = (X_{2\pi_1}, \dots, X_{2\pi_n})\},$$

где π_1, \dots, π_n — перестановка индексов $1, \dots, n;$

$$|G| = n!$$

Достижимый уровень значимости:

$$p(t) = \begin{cases} \frac{\sum_{g \in G} [T(X_1^n, gX_2^n) \leq t]}{n!}, & H_0: r_{X_1 X_2} = 0, \\ \frac{\sum_{g \in G} [|T(X_1^n, gX_2^n) - t| \geq |T(X_1^n, X_2^n) - t|]}{n!}, & H_1: r_{X_1 X_2} \neq 0. \end{cases}$$

Перестановочный критерий

Перестановочный $100(1 - \alpha)\%$ -% доверительный интервал для коэффициента корреляции образован выборочными квантилями порядка $\alpha/2$ и $1 - \alpha/2$ перестановочного распределения $T(X_1^n, gX_2^n)$.

Пример: в предыдущем примере

$$H_0: r_{X_1 X_2} = 0.$$

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

Недостатки

Недостатки выборочного коэффициента Пирсона:

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

Корреляция Спирмена


Коэффициент корреляции Спирмена — коэффициент корреляции Пирсона рангов наблюдений в выборках X_1^n, X_2^n :

$$\begin{aligned} \rho_{X_1 X_2} &= \frac{\sum_{i=1}^n \left(r(X_{1i}) - \frac{n+1}{2} \right) \left(r(X_{2i}) - \frac{n+1}{2} \right)}{\frac{1}{12} (n^3 - n)} = \\ &= 1 - \frac{6}{n^3 - n} \sum_{i=1}^n (r(X_{1i}) - r(X_{2i}))^2, \end{aligned}$$

где $r(X_{1i}), r(X_{2i})$ — ранги i -х наблюдений в соответствующих выборках.

$\rho_{X_1 X_2} \in [-1, 1]$ — мера **монотонной** связи.

Корреляция Спирмена



Корреляция Спирмена

(0.84; 0.97)



(0.65; 0.86)



(0.12; 0.16)



(0; 0)



(0.12; 0.16)



(0.65; 0.86)



(0.84; 0.97)



(1; 1)



(0.79; 0.95)



(0.6; 0.82)



(0.42; 0.63)



(0.25; 0.39)



(0.13; 0.21)



(0; 0)



(0.7; 0.9)



(0.69; 0.88)



(0.65; 0.86)



(0.6; 0.82)



(0.42; 0.65)



(0.23; 0.4)



(0.07; 0.14)



Критерий Стьюдента


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

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

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

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

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



достигаемый уровень значимости:

$$p(t) = \begin{cases} 1 - tcdf(t, n-2), & H_1: \rho_{X_1 X_2} > 0, \\ tcdf(t, n-2), & H_1: \rho_{X_1 X_2} < 0, \\ 2(1 - tcdf(|t|, n-2)), & H_1: \rho_{X_1 X_2} \neq 0. \end{cases}$$

Критерий Стьюдента

Пример: выборка из 11 потребителей вегетарианских 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 — мера взаимной неупорядоченности X_1^n и X_2^n :

$$\tau_{X_1 X_2} = 1 - \frac{4}{n(n-1)} \sum_{i=1}^{n-1} \sum_{j=1}^n [[X_{1i} < X_{1j}] \neq [X_{2i} < X_{2j}]] = \frac{C - D}{C + D},$$

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

$\tau_{X_1 X_2} \in [-1, 1]$ — мера **монотонной** связи.

Корреляция Кендалла



Корреляция Кендалла

(0.84; 0.97)



(0.65; 0.86)



(0.12; 0.16)



(0; 0)



(0.12; 0.16)



(0.65; 0.86)



(0.84; 0.97)



(1; 1)



(0.79; 0.95)



(0.6; 0.82)



(0.42; 0.63)



(0.25; 0.39)



(0.13; 0.21)



(0; 0)



(0.7; 0.9)



(0.69; 0.88)



(0.65; 0.86)



(0.6; 0.82)



(0.42; 0.65)



(0.23; 0.4)



(0.07; 0.14)



Критерий без названия

выборки: $X_1^n = (X_{11}, \dots, X_{1n}),$
 $X_2^n = (X_{21}, \dots, X_{2n}),$ 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: 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 $D = 5$, $S = 38$, $\tau_{X_1 X_2} = 0.7821$.


$$H_0: \tau_{X_1 X_2} = 0.$$

$$H_1: \tau_{X_1 X_2} \neq 0 \Rightarrow p = 0.0027.$$

Связь между коэффициентами корреляции

При справедливости H_0 (отсутствии монотонной зависимости):

$$r_{\rho_{X_1 X_2} \tau_{X_1 X_2}} = \frac{2n + 2}{\sqrt{4n^2 + 10n}}.$$



Кендалла vs. Спирмена: <http://youtu.be/D56dvoVrBBE>

Корреляция Кендалла:

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

Связь между коэффициентами корреляции

Если $(X_{1i}, X_{2i}) \sim N(\mu, \Sigma)$, то

$$\lim_{n \rightarrow \infty} \mathbb{E} \tau_{X_1 X_2} = \lim_{n \rightarrow \infty} \mathbb{E} \rho_{X_1 X_2} = \frac{2}{\pi} \arcsin r_{X_1 X_2}.$$

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:

$$r_{X_1 X_2 | X_3} = \frac{r_{X_1 X_2} - r_{X_1 X_3} r_{X_2 X_3}}{\sqrt{(1 - r_{X_1 X_3}^2)(1 - r_{X_2 X_3}^2)}}.$$

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

$$r_{X_1 X_2 | X_3 X_4} = \frac{r_{X_1 X_2 | X_4} - r_{X_1 X_3 | X_4} r_{X_2 X_3 | X_4}}{\sqrt{(1 - r_{X_1 X_3 | X_4}^2)(1 - r_{X_2 X_3 | X_4}^2)}}.$$

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

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

Критерий Стьюдента


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

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

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



достигаемый уровень значимости:

$$p(t) = \begin{cases} 1 - tcdf(t, n - M - 2), & H_1: r_{X_2 X_2 | X_3} > 0, \\ tcdf(t, n - M - 2), & H_1: r_{X_2 X_2 | X_3} < 0, \\ 2(1 - tcdf(|t|, n - M - 2)), & H_1: r_{X_2 X_2 | X_3} \neq 0. \end{cases}$$

Множественная корреляция

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

$$r_{X_1, X_2, X_3} = \frac{r_{X_1 X_2}^2 + r_{X_1 X_3}^2 - 2r_{X_1 X_2} r_{X_1 X_3} r_{X_2 X_3}}{1 - r_{X_2 X_3}^2}.$$

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

$$r_{X, M}^2 = c^T R c.$$

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

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

Критерий Фишера


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

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

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

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

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




достигаемый уровень значимости:


$$p(f) = 1 - fcdf(f, M - 2, n - M - 1).$$

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	$0.235 \cdot \lambda - 0.638 \cdot \phi$	$0.397 \cdot \lambda - 0.678 \cdot T$	$1.542 \cdot T + 2.450 \cdot \phi$




Вес и линейные размеры рыб

В 1917 году в финском озере Längelmävesi исследователи поймали и измерили 81 рыбу трёх схожих видов. Известны: вес, длина от носа до начала хвоста, длина от носа до развилки хвоста, длина от носа до кончика хвоста, наибольшая высота, наибольшая толщина. Исследовать взаимосвязи между переменными.



Вес и линейные размеры рыб



Вес и линейные размеры рыб

Попарные корреляции Пирсона:

<i>r</i>	Weight	Length1	Length2	Length3	Width	Thickness
Weight	-	0.9575	0.9581	0.9545	0.9527	0.9584
Length1	0.9575	-	0.9996	0.9974	0.9753	0.9718
Length2	0.9581	0.9996	-	0.9973	0.9754	0.9724
Length3	0.9545	0.9974	0.9973	-	0.9822	0.9707
Width	0.9527	0.9753	0.9754	0.9822	-	0.9734
Thickness	0.9584	0.9718	0.9724	0.9707	0.9734	-

Наибольший достигаемый уровень значимости: $p = 2.8772 \times 10^{-43}$.

Вес и линейные размеры рыб

Попарные корреляции Кендалла:

τ	Weight	Length1	Length2	Length3	Width	Thickness
Weight	-	0.9125	0.9162	0.9177	0.8805	0.8827
Length1	0.9125	-	0.9834	0.9609	0.8467	0.8558
Length2	0.9162	0.9834	-	0.9520	0.8444	0.8631
Length3	0.9177	0.9609	0.9520	-	0.8720	0.8540
Width	0.8805	0.8467	0.8444	0.8720	-	0.8223
Thickness	0.8827	0.8558	0.8631	0.8540	0.8223	-

Наибольший достигаемый уровень значимости: $p = 1.3078 \times 10^{-26}$.

Вес и линейные размеры рыб

Попарные корреляции Спирмена:

ρ	Weight	Length1	Length2	Length3	Width	Thickness
Weight	-	0.9871	0.9864	0.9881	0.9738	0.9715
Length1	0.9871	-	0.9984	0.9955	0.9627	0.9638
Length2	0.9864	0.9984	-	0.9933	0.9594	0.9655
Length3	0.9881	0.9955	0.9933	-	0.9719	0.9637
Width	0.9738	0.9627	0.9594	0.9719	-	0.9440
Thickness	0.9715	0.9638	0.9655	0.9637	0.9440	-

Наибольший достигаемый уровень значимости: $p = 8.4691 \times 10^{-40}$.

Вес и линейные размеры рыб

Частные корреляции Пирсона:

<i>r</i>	Weight	Length1	Length2	Length3	Width	Thickness
Weight	-	0.0458	0.0880	-0.2054	0.2404	0.2372
Length1	0.0458	-	0.8847	0.2814	-0.1484	0.0318
Length2	0.0880	0.8847	-	0.1743	-0.0958	0.1314
Length3	-0.2054	0.2814	0.1743	-	0.6557	-0.2526
Width	0.2404	-0.1484	-0.0958	0.6557	-	0.4690
Thickness	0.2372	0.0318	0.1314	-0.2526	0.4690	-

Достигаемые уровни значимости:

<i>p</i>	Weight	Length1	Length2	Length3	Width	Thickness
Weight	-	0.6926	0.4466	0.0731	0.0352	0.0378
Length1	0.6926	-	0.0000	0.0132	0.1976	0.7840
Length2	0.4466	0.0000	-	0.1294	0.4070	0.2546
Length3	0.0731	0.0132	0.1294	-	0.0000	0.0266
Width	0.0352	0.1976	0.4070	0.0000	-	0.0000
Thickness	0.0378	0.7840	0.2546	0.0266	0.0000	-

Вес и линейные размеры рыб

Частные корреляции Спирмена:

ρ	Weight	Length1	Length2	Length3	Width	Thickness
Weight	-	0.0626	0.1041	0.0956	0.4291	0.3943
Length1	0.0626	-	0.8515	0.5177	-0.0510	-0.1310
Length2	0.1041	0.8515	-	-0.0940	-0.1433	0.1887
Length3	0.0956	0.5177	-0.0940	-	0.4051	0.0327
Width	0.4291	-0.0510	-0.1433	0.4051	-	-0.0165
Thickness	0.3943	-0.1310	0.1887	0.0327	-0.0165	-

Достигаемые уровни значимости:

p	Weight	Length1	Length2	Length3	Width	Thickness
Weight	-	0.5885	0.3674	0.4083	0.0001	0.0004
Length1	0.5885	-	0.0000	0.0000	0.6598	0.2562
Length2	0.3674	0.0000	-	0.4163	0.2139	0.1003
Length3	0.4083	0.0000	0.4163	-	0.0003	0.7774
Width	0.0001	0.6598	0.2139	0.0003	-	0.8869
Thickness	0.0004	0.2562	0.1003	0.7774	0.8869	-

Вес и линейные размеры рыб

Множественная корреляция всех признаков с весом: $R = 0.9207$ ($p \approx 0$).

Максимизирующая корреляцию линейная комбинация:

$$292.2458 \cdot \text{Length1} - 151.1554 \cdot \text{Length2} - 151.0027 \cdot \text{Length3} + 148.8896 \cdot \text{Width} + 83.4345 \cdot \text{Thickness}.$$




Таблица сопряженности 2×2

Имеются связанные выборки $X_1^n = (X_{11}, \dots, X_{1n})$ и $X_2^n = (X_{21}, \dots, X_{2n})$.
Пусть X_{1i} и X_{2i} принимают значения 0 и 1.

№	X_1	X_2
1	0	0
2	1	1
3	0	1
⋮	⋮	⋮
n	1	0

\Rightarrow

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

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.


Критерий Мак-Нимара

выборки: $X_1^n = (X_{11}, \dots, X_{1n}), X_{1i} \sim Ber(p_1),$
 $X_2^n = (X_{21}, \dots, X_{2n}), X_{2i} \sim Ber(p_2),$ выборки связанные;

нулевая гипотеза: $H_0: X_1$ и X_2 независимы

альтернатива: $H_1: H_0$ неверна;

статистика: $\chi^2(X_1^n, X_2^n) = \frac{n(|b-c|-0.5)^2}{b+c};$
 $\chi^2(X_1^n, X_2^n) \sim \chi_1^2$ при $H_0;$



достигаемый уровень значимости:

$$p(\chi^2) = 1 - \text{chi2cdf}(\chi^2, 1).$$

Критерий Мак-Нимара

Условия применимости критерия:

- $n \geq 40$;
- $a, b, c, d > 5$.

Критерий Мак-Нимара

Пример: исследуется влияние препарата на симптом некоторого заболевания.

		После лечения	
	До лечения	Есть	Нет
Есть		101	121
Нет		59	33

$b = 121$ — испытуемые, у которых симптом после приёма препарата исчез,
 $c = 59$ — испытуемые, у которых симптом появился.
 $MCC = -0.1673$.

H_0 : препарат не влияет на наличие симптома.
 H_1 : препарат влияет на наличие симптома $\Rightarrow p = 4.5689 \times 10^{-6}$.

Анализ зависимостей независимых выборок

Имеются независимые выборки $X_1^{n_1} = (X_{11}, \dots, X_{1n_1})$ и $X_2^{n_2} = (X_{21}, \dots, X_{2n_2})$, $n_1 + n_2 = n$, X_{1i} и X_{2i} принимают значения 0 и 1. Данные можно представить сходным образом:

№	$\in X_1$	Значение
1	1	0
2	0	1
3	0	0
⋮	⋮	⋮
n	1	1



Выборка \ Значение	Значение		Σ
	0	1	
X_1	a	b	$n_1 = a + b$
X_2	c	d	$n_2 = c + d$
Σ	$a + c$	$b + d$	n

Признаки "выборка" и "значение" независимы \Leftrightarrow выборки X_1 и X_2 однородны.

Критерий хи-квадрат


выборки: $X_1^{n_1} = (X_{11}, \dots, X_{1n_1}), X_{1i} \in \{0, 1\},$
 $X_2^{n_2} = (X_{21}, \dots, X_{2n_2}), X_{2i} \in \{0, 1\},$

выборки независимые;

нулевая гипотеза: $H_0: X_{1i}$ и X_{2j} однородны,

альтернатива: $H_1: H_0$ неверна;

статистика: $\chi^2(X_1^{n_1}, X_2^{n_2}) = \frac{n(ad-bc)^2}{(a+b)(a+c)(b+d)(c+d)};$
 $\chi^2(X_1^{n_1}, X_2^{n_2}) \sim \chi_1^2$ при $H_0;$



достигаемый уровень значимости:

$$p(\chi^2) = 1 - \text{chi2cdf}(\chi^2, 1).$$

Критерий хи-квадрат

Критерий эквивалентен Z-критерию для сравнения двух пропорций.

Условия применимости критерия:

- $n \geq 40$;
- $a, b, c, d > 5$.

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

$$MCC = 0.0122.$$

H_0 : препарат неотличим от плацебо.

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

Точный критерий Фишера

выборки: $X_1^{n_1} = (X_{11}, \dots, X_{1n_1}), X_{1i} \in \{0, 1\},$
 $X_2^{n_2} = (X_{21}, \dots, X_{2n_2}), X_{2i} \in \{0, 1\},$
выборки независимые;

нулевая гипотеза: $H_0: X_{1i}$ и X_{2j} однородны,

альтернатива: $H_1: H_0$ неверна.

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

$$P(X_1^{n_1}, X_2^{n_2}) = \frac{(a+b)!(c+d)!(a+c)!(b+d)!}{a!b!c!d!n!}.$$

Достижимый уровень значимости определяется как сумма по всем возможным вариантам таблицы с такими же суммами по строкам и столбцам, имеющим вероятность не более $P(X_1^{n_1}, X_2^{n_2})$.

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 24 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

$$MCC = -0.6953.$$

H_0 : связи нет.

H_1 : признаки связаны $\Rightarrow p = 0.0014$.

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)


Bikel at el., Sex Bias in Graduate Admissions: Data from Berkeley, 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	
	Σ	+	Σ	+
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.



Прикладная статистика
6. Анализ зависимостей.

Рябенко Евгений
riabenko.e@gmail.com