

*Сложные проблемы всегда имеют простые,
легкие для понимания неправильные решения.*

Мерфология

Проверка гипотезы о независимости двух выборок

Для проверки гипотезы о независимости двух выборок X и Y используется таблица частот, которые можно было бы ожидать в том случае, если переменные оказались бы независимыми. В общем случае критерий χ^2 независимости принято применять следующим образом.

1. Множество значений выборки X разбивается на s непересекающихся классов (интервалов, разрядов), а множество значений Y на r непересекающихся интервалов.
2. Составляется **таблица исходных данных** в виде списка экспериментальных частот Z_{ij} всех комбинаций категорий двух качественных переменных.



Таблица дополняется строкой и столбцом сумм "попаданий" компонент выборки в конкретный класс другой выборки:

$$Z_{Yk} = \sum_i Z_{ik}, k = 1, \dots, r$$

$$Z_{Xk} = \sum_j Z_{kj} k = 1, \dots, s$$

Переменные (выборки), разделенные по классам
(экспериментальные частоты)

интервалы $i=1,2,\dots,s$ выборки X	интервалы $j=1,2,\dots,r$ выборки Y				
	элементы Y_1	элементы Y_2	***	элементы Y_r	
элементы X_1	Z_{11}	Z_{12}	***	Z_{1r}	$Z_{X1} = \sum_j Z_{1j}$
элементы X_2	Z_{21}	Z_{22}	***	Z_{2r}	$Z_{X2} = \sum_j Z_{2j}$
***	***	***	***	***	***
элементы X_s	Z_{s1}	Z_{s2}	***	Z_{sr}	$Z_{Xs} = \sum_j Z_{sj}$
	$Z_{Y1} = \sum_i Z_{i1}$	$Z_{Y2} = \sum_i Z_{i2}$	***	$Z_{Yr} = \sum_i Z_{ir}$	$n = \sum_i \sum_j Z_{ij}$

3. Составляется таблица "относительных частот" по соотношению

$$T_{ij} = \frac{Z_{ij}}{Z_{Yj} Z_{Xi}}, i = 1, \dots, s, j = 1, \dots, r.$$

Переменные (выборки), разделенные по классам

	элементы Y_1	элементы Y_2	***	элементы Y_r
элементы X_1	T_{11}	T_{12}	***	T_{1r}
элементы X_2	T_{21}	T_{22}	***	T_{2r}
***	***	***	***	***
элементы X_s	T_{s1}	T_{s2}	***	T_{sr}

4. Определяется расчетное значение χ^2 по формуле

$$\chi^2_{\text{расч}} = n \left(\sum_i \sum_j T_{ij} - 1 \right).$$

5. Критическое значение $\chi^2_{\text{кр}}$ (s категорий X и r категорий Y) определяется для числа степеней свободы $df = (s - 1)(r - 1)$.

6. Проводится сравнение расчетного значения $\chi^2_{\text{расч}}$ с критическим $\chi^2_{\text{кр}}$, определенному по "обычным" уровням значимости α , равному 0,05 или 0,01 или другому выбранному значению.

7. Строится заключение: при $\chi^2_{\text{расч}} > \chi^2_{\text{кр}}$ гипотеза об отсутствии связи между признаками и параметрами отвергается, при $\chi^2_{\text{расч}} < \chi^2_{\text{кр}}$ - подтверждается.

Пример П5. По переписи населения Швеции 1936 г. из совокупности всех супружеских пар была получена выборка (данные в таблице), содержащая распределение годовых доходов (в тыс. крон) и количества детей в семье¹.

Распределение годовых доходов (в тыс. крон) и количества детей в семье

число детей	доходы, тыс. крон			
	0-1	1-2	2-3	3 и выше
0	2161	3577	2184	1636
1	2755	5081	2222	1052
2	936	1753	640	306
3	225	419	96	38
4 и более	39	98	31	14

Требуется установить на уровне значимости $\alpha=0,05$ (с доверительной вероятностью 0,95) являются ли зависимыми количество детей в семье (величина X) и уровень годового дохода этой семьи (величина Y).

Для проверки гипотезы H_0 о независимости X и Y используется критерий χ^2 . Множество значений X (количество детей в семье) разбивается на 5 разрядов, множество значений Y (годовой доход семьи) разбито на 4 разряда (см. [таблицу доходов](#)). Алгоритм построения решения следующий.

¹ Гланц, С. Медико-биологическая статистика / С. Гланц, –М.: Практика, 1998. –459 с.

1. В диапазон B5:T9 заносятся исходные данные по выборкам X и Y. В ячейку F1 вводится значение величины уровня значимости. В требуемые ячейки (рис. П5.1) заносятся поясняющие данные.
2. В ячейку B10 вводится формула =СУММ(B5:B9) {=SUM(B5:B9)} подсчета суммы первой группы выборки Y по всей X. Формула тиражируется автозаполнением на диапазон C10:F10. В ячейку F5 вводится формула =СУММ(B5:E5) {=SUM(B5:E5)} подсчета суммы первой группы выборки X по всей Y. Формула тиражируется автозаполнением на диапазон F6:F9.
3. В ячейку B13 вводится формула =B5/B\$10*B5/\$F5 подсчета "относительной частоты" суммарной выборки. Формула тиражируется автозаполнением на диапазон B13:E17.
4. В ячейку B19 вводится формула =F10*(СУММ(B13:E17)-1) {=F10*(SUM(B13:E17)-1)}, реализующая подсчет критерия χ^2 в соответствии с соотношением

$$\chi_{\text{расч}}^2 = n \left(\sum_i \sum_j T_{ij} - 1 \right).$$

5. В ячейке B20 формулой =F10*(СУММ(B13:E17)-1) {=F10*(SUM(B13:E17)-1)} подсчитывается число степеней свободы, а формулой =ХИ2ОБР(F1;B21) {=CHIINV(F1;B21)} определяется критическое значение статистики $\chi_{\text{кр}}^2$.
6. Поскольку $\chi_{\text{расч}}^2 > \chi_{\text{кр}}^2$, то гипотеза H_0 о независимости X (количество детей в семье) и Y (уровень годового дохода семьи) отвергается с доверительной вероятностью 95%.

	A	B	C	D	E	F
1	Нулевая гипотеза: выборки X и Y независимы				$\alpha =$	0,05
2						
3	выборка X	доход, тыс. крон (Y)			=СУММ(B5:E5)	
4	количество детей	0-1	1-2	2-3	≥ 3	
5	0	2161	3577	2184	1636	9558
6	1	2755	5081	2222	1052	11110
7	2	936	1753	640	306	3635
8	3	225	419	96	38	778
9	4 и более	39	98	31	14	182
10	=СУММ(B5:B9)	6116	10928	5173	3046	25263
11						
12						
13		0,0799	0,1225	0,0965	0,0919	
14	=B5/B\$10*B5/\$F5	0,1117	0,2126	0,0859	0,0327	
15		0,0394	0,0774	0,0218	0,0085	
16		0,0106	0,0206	0,0023	0,0006	
17		0,0014	0,0048	0,0010	0,0004	
18						
19	$\chi^2_{расч} =$	568,6	=F10*(СУММ(B13:E17)-1)			
20						
21	df =	12	=(СЧЁТ(B5:B9)-1)*(СЧЁТ(B5:E5)-1)			
22						
23	$\chi^2_{кр} =$	21,0	=ХИ2ОБР(F1;B21)			
24						
25	поскольку $\chi^2_{расч} > \chi^2_{кр}$ то					
26						
27	Ответ: Гипотеза H_0 о независимости X (количество детей					
28	в семье) и Y (уровень годового дохода семьи) отвергается					

Рис. П5.1. Скриншот расчетного листа MS Excel