

第6章 分类数据关联分析



中国人民大学统计学院

什么是分类数据

- 统计数据的一种。指反映事物类别的数据。如人按性别分为男、女两类。
- 分类数据 (categorical data) 是离散数据(discrete data)。分类属性具有有限个 (但可能很多) 不同值, 值之间无序。
- 例子: 200例肿瘤患者中A指标阳性100例, 阴性100例; B指标阳性50例, 阴性150例。AB都是分类变量。有AB同时阳性的患者20例, 想看AB之间是否存在相关。

中国人民大学统计学院

本章内容

```

graph TD
    A[分类数据关联性检验] --> B[卡方独立性检验]
    A --> C[卡方齐性检验]
    A --> D[Fisher精确检验]
    A --> E[Ridit检验]
    A --> F[对数线性模型]
    B --> G[McNemar检验]
    B --> H[Mantel-Haenszel检验]
  
```

中国人民大学统计学院

问题：两个分类变量有关系吗？如何度量？

不良习惯 ----- 健康

	得肺病		没有肺病	
吸烟	80	0	40	
	0	90	20	

$$P(\text{得肺病}|\text{吸烟}) = \frac{2}{3}$$

明德主楼1019 王星 wangxingscy@gmail.com 82500167 | 中国人民大学统计学院

6.1 χ^2 列联表和 χ^2 检验

	B_1	B_2	\cdots	B_s	总和
A_1	n_{11}	n_{12}	\cdots	n_{1s}	$n_{1\cdot}$
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
A_r	n_{r1}	n_{r2}	\cdots	n_{rs}	$n_{r\cdot}$
总和	$n_{\cdot 1}$	$n_{\cdot 2}$	\cdots	$n_{\cdot s}$	$n_{\cdot \cdot}$

$n_i = \sum_{j=1}^s n_{ij}, i = 1, 2, \dots, r,$ 表示各行之和;

$n_{\cdot j} = \sum_{i=1}^r n_{ij}, j = 1, 2, \dots, s,$ 表示各列之和;

$n_{\cdot \cdot} = \sum_{j=1}^s n_{\cdot j} = \sum_{i=1}^r n_{i\cdot}$

中国人民大学统计学院

χ^2 独立性检验

假设检验问题:

$$H_0: p_{ij} = p_{i\cdot} \cdot p_{\cdot j}$$

构造统计量:

$$\chi^2 = \sum_{i,j} \frac{(n_{ij} - e_{ij})^2}{e_{ij}} = \sum_{i,j} \frac{(n_{ij})^2}{e_{ij}} - n_{\cdot \cdot}$$

$$e_{ij} = \frac{n_{i\cdot} \cdot n_{\cdot j}}{n_{\cdot \cdot}}$$

$$\chi^2 \rightarrow \chi^2_{(r-1)(s-1)}$$

当 χ^2 取大值, 或者 p -值很小的时候, 拒绝零假设。

中国人民大学统计学院

交叉分析

性別 \times 血型 * 可以嵌套的双列机的表格 Crosstabulation

		血型				Total		
		1000元以下	1001-2000元	2001-3000元	3000-6000元	6001以上	Total	
性別	男	COUNT	31	115	85	64	21	316
		% within 总	9.6%	36.4%	26.9%	20.4%	6.6%	100.0%
		% within 血型	11.2%	39.7%	47.5%	83.1%	44.7%	36.4%
性別	女	% of Total	3.6%	13.2%	9.8%	7.4%	2.4%	36.4%
		COUNT	245	175	94	13	26	553
		% within 总	44.3%	31.6%	17.0%	2.4%	4.7%	100.0%
性別	女	% within 血型	88.8%	60.3%	52.5%	16.9%	55.3%	63.6%
		% of Total	28.2%	20.1%	10.8%	1.5%	3.0%	63.6%
		Total	276	290	179	77	47	869
性別	女	COUNT	100.0%	100.0%	100.0%	100.0%	100.0%	100.0%
		% of Total	31.8%	33.4%	20.6%	8.9%	5.4%	100.0%
		% of Total	31.8%	33.4%	20.6%	8.9%	5.4%	100.0%

注意：

1. 交叉列联表中的期望数<5的格点数不超过20%，方可进行Chi square检验。
2. 只有当交叉列联检验通过，才可认为行变量和列变量存在关系，否则只能视为独立。

a. 0 cells (.0%) have expected count less than 5. The minimum expected count is 17.09.

明德主楼1019

中国人民大学统计学院

例6.1

例6.1：为研究血型与肝病之间的关系，对295名肝病患者及638名非肝病患者（对照组），调查不同血型的得病情况，如表所示，问血型与肝病之间是否存在关联。

表 6.2. 血型与肝病间的关系

	血型	肝炎	肝硬化	对照	合计
O	98	38	289	425	
A	67	41	262	370	
B	13	8	57	78	
AB	18	12	30	60	
合计	196	99	638	933	

中国人民大学统计学院

解答

本例中的行和列都是分类变量，因而可用 chisq.test 求出 Pearson χ^2 值，如下所示：

```
> blood <- read.table("bloodtyp.txt", header=T)
> chisq.test(blood)

Pearson's chi-square test with Yates' continuity correction
data: blood
X-squared = 15.073, df = 6, p-value = 0.020
```

表中输出了 Pearson χ^2 检验结果，自由度为 $(3-1)(4-1) = 6$ ， χ^2 值为 15.073， p 值为 0.020，由于 p 值小于 0.05，可以拒绝血型与病种独立的假设，认为血型与肝病有一定关联。C=0.1294459

中国人民大学统计学院

6.2 齐性检验 例6.2

例6.2：对479个不同年龄段的人调查他们对种不同类型电视节目的喜爱情况，要求每人只能选出他们最喜欢观看的电视节目类型，结果如下：

表 6.3. 不同年龄层次的人与电视节目类型之间的关系

年龄段	体育类 1	电视剧类 2	综艺类 3	总和
≤ 30	83	70	45	198
31 - 50	91	86	15	192
> 50	41	38	10	89
总和	215	194	70	479

问题是想了解不同观众对三类节目的关注率是否一样。

假设检验问题是：

$$\forall i = 1, \dots, r, H_0 : p_{i1} = \dots = p_{ir} = p_i \leftrightarrow H_1 : \text{等式不全相等}$$

构造统计量：

$$Q = \sum_{i,j} \frac{(n_{ij} - e_{ij})^2}{e_{ij}} = \sum_{i,j} \frac{(n_{ij})^2}{e_{ij}} - n_{..} \quad e_{ij} = \frac{n_i \cdot n_j}{n_{..}}$$

在零假设下近似有： $\chi^2 \rightarrow \chi^2_{(r-1)(s-1)}$

检验方法和独立性检验相同。

χ^2 齐性检验

假设检验问题：

$$\forall i = 1, \dots, r, H_0 : p_{i1} = \dots = p_{ir} = p_i \leftrightarrow H_1 : \text{等式不全相等}$$

构造统计量：

	B_1	B_2	\dots	B_s	总和
A_1	n_{11}	n_{12}	\dots	n_{1s}	$n_{1..}$
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
A_r	n_{r1}	n_{r2}	\dots	n_{rs}	$n_{r..}$
总和	$n_{..1}$	$n_{..2}$	\dots	$n_{..s}$	$n_{...}$

中国人民大学统计学院

中国人民大学统计学院

齐性检验

- $H_0 : p_{11} = p_{12} = \dots = p_{1s}$
- 在 H_0 之下，对 p_{1i} 最好的估计是 $\hat{p}_{1i} = n_{1i}/n$
- 对交叉列联表的每个单元格而言，我们希望测量观测频数和期望频数的差异： $(n_{ij} - \hat{n}_{ij})^2 / \hat{n}_{ij}$
- 将上面的结果平方再标准化得到统计量 χ^2_{calc}
- 注意到 $E_{ij} = \hat{p}_{1i} \cdot \hat{p}_{1j} = (n_{1i})(n_{1j})/n$ 这个形式和独立性检验的形式是一致的。

中国人民大学统计学院

解答

例 6.2: 对 479 个不同年龄段的人调查他们对种不同类型电视节目的喜爱情况, 要求每人只能选出他们最喜欢观看的电视节目类型, 结果如下:

年龄段	体育类	电视剧类	综艺类	总和
≤ 30	83	70	45	198
31~50	91	86	15	192
> 50	41	38	10	89
总和	215	194	70	479

问题是否不同观众对三类节目的关注程度是否一样。

假设检验问题是:

$\forall i = 1, \dots, r, H_0: p_{i1} = \dots = p_{ir} = p_i \leftrightarrow H_1: \text{等式不全成立.}$

χ^2 检验统计量为

$$Q = \sum_{ij} \frac{(n_{ij} - e_{ij})^2}{e_{ij}} = \sum_{ij} \frac{n_{ij}^2}{e_{ij}} - n_{..}$$

该 χ^2 统计量和独立性检验的统计量形式上完全一致, 近似服从自由度为 $(r-1)(c-1)$ 的 χ^2 分布. 该例子的 $Q = 11.927$, p -值为 0.00179; 因此可以在水平 $\alpha \geq 0.002$ 时拒绝零假设.

讨论题:

多样本检验和 χ^2 检验相似之处和区别

中国人民大学统计学院

Riddle of Jane Austen



Word	Sense	Emma	Sanditon	Sanditon
a	147	186	101	83
an	25	26	11	29
this	32	39	15	15
that	94	105	37	22
Pearson's Chi-squared test with	59	74	28	43
without	18	10	10	4

data: Jane
 X-squared = 45.5775, df = 15, p-value = 6.205e-05

中国人民大学统计学院

6.3 Fisher精确检验

2*2列联表

	B ₁	B ₂	总和
A ₁	n ₁₁	n ₁₂	n _{1..}
A ₂	n ₂₁	n ₂₂	n _{2..}
总和	n _{..1}	n _{..2}	n _{..}

在 A、B 独立时:

$$P\{n_{ij}\} = \frac{n_{..1}!n_{..2}!n_{1..}!n_{2..}!}{n_{..}!n_{11}!n_{12}!n_{21}!n_{22}!} \quad P(n_{11}) = \frac{\binom{n_{..1}}{n_{11}} \binom{n_{..2}}{n_{21}}}{\binom{n_{..}}{n_{1..}}}$$

中国人民大学统计学院

检验fisher.test

任何一个格子中的数目都不会过大或者过小, 如果过大或者过小就可以考虑拒绝零假设, 因而我们考虑 n_{11} 就可以了. 当大样本时, 可以采用近似正态分布进行检验, 即:

$$Z = \frac{\sqrt{n_{..}}(n_{11}n_{22} - n_{12}n_{21})}{\sqrt{n_{1..}n_{2..}n_{1..}n_{2..}}} \rightarrow N(0,1)$$

中国人民大学统计学院

例 6.3

例 6.3: 为了解某种药物治疗效果, 结果见下表:

表 6.5. 某病两种药物治疗结果

		疗效		合计
		药物	有效	
A		8	2	10
B		14	18	32
合计		22	20	42

解: 统计计算: 如果固定边缘值 (10,32,22,20), 那么在零假设条件下出现在四格表中各数值分别为 n_{11}, n_{12}, n_{21} 及 n_{22} 的概率按超几何分布为:

$$\begin{aligned} P\{n_{11} = 8\} &= \frac{n_{1..}!n_{2..}!n_{1..}!n_{2..}!}{n!n_{11}!n_{12}!n_{21}!n_{22}!} \\ &= \frac{10!32!22!20!}{42!8!2!14!18!} = 0.0412 \end{aligned}$$

如果用 fisher.test 可以计算得到 $P(n_{11} \geq 8) = 0.0709$.

中国人民大学统计学院

6.4 Mantel-Haenszel检验

		A		B	
		存活	死亡	存活	死亡
		42	54	47	33
		20	14	17	25
		Pearson's Chi-square continuity correction		data: UU	
				X-squared = 3.3506, df = 1, p-value = 0.06718	

中国人民大学统计学院

h 表示多层四格表的第 h 层, 第 h 层观测病案数为 n_h , $\sum_{h=1}^k n_h = n$.

假设检验问题为
 H_0 : 试验组与对照组在治疗效果上没有差异;
 H_1 : 试验组与对照组在治疗效果上存在差异.

下表是第 h 层四格表的符号表示.

	有效	无效	合计
试验组	n_{h11}	n_{h12}	n_{h1}
对照组	n_{h21}	n_{h22}	n_{h2}
合计	n_h	n_h	n_h

当零假设 H_0 成立时, 先求出第 h 层 n_{h11} 的期望 En_{h11} 和方差 $\text{var}(n_{h11})$:

$$En_{h11} = \frac{n_{h1} n_{h1}}{n_h},$$

$$\text{var}(n_{h11}) = \frac{n_{h1} n_{h2} n_h (n_h - 1)}{n_h^2 (n_h - 1)}.$$

$$Q_{MH} = \frac{\left(\sum_{h=1}^k n_{h11} - \sum_{h=1}^k En_{h11} \right)^2}{\sum_{h=1}^k \text{var}(n_{h11})}.$$

中国人民大学统计学院

表 6.6 不同医院治疗药物效果比较

医院	药品	有效	无效	合计
		1	A	
1	A	50	15	65
1	B	92	90	182
	合计	142	105	247
2	药品	有效	无效	合计
		2	B	

医院	药品	有效	无效	合计
		2	A	
2	A	47	135	182
2	B	5	60	65
	合计	52	195	247

解 R 程序如下:

```
chisq.test(matrix(c(97,150,97,150),2,2))
Pearson's Chi-squared test
data: matrix(c(97, 150, 97, 150), 2, 2)
X-squared = 0, df = 1, p-value = 1
```

Mantel-Haenszel chi-squared test with continuity correction
data: x
Mantel-Haenszel X-squared = 21.9443, df = 1, p-value = 2.807e-06
alternative hypothesis: true common odds ratio is not
>

中国人民大学统计学院

Simpson悖论(女>男|商, 女>男|法, 女? 男|法+商)

例题:一所美国高校的两个学院,分别是法学院和商学院,新学期招生。人们怀疑这两个学院有性别歧视。

性别	录取	拒收	总数	录取比例
男生	209	95	304	68.8%
女生	143	110	253	56.5%
合计	352	205	557	

法学院

性别	录取	拒收	总数	录取比例
男生	8	45	53	15.1%
女生	51	101	152	33.6%
合计	59	146	205	

商学院

性别	录取	拒收	总数	录取比例
男生	201	50	251	80.1%
女生	92	9	101	91.1%
合计	293	59	352	

申请性别

女 男 录取率

法学院 商学院 法学院 商学院

中国人民大学统计学院

配对设计两样本率比较的 χ^2 检验 (mcnemar.test)

中国人民大学统计学院

方法原理

- 例6.9 用A、B两种方法检查已确诊的乳腺癌患者140名, A法检出91名(65%), B法检出77名(55%), A、B两法一致的检出56名(40%), 问哪种方法阳性检出率更高?

A法	B法		合计
	+	-	
+	56 (a)	35 (b)	91
-	21 (c)	28 (d)	49
合计	77	63	140

中国人民大学统计学院 23

方法原理

- 显然,本例对同一个个体有两次不同的测量,从设计的角度上讲可以被理解为自身配对设计
- 按照配对设计的思路进行分析,则首先应当求出各对的差值,然后考察样本中差值的分布是否按照 H_0 假设的情况对称分布
- 按此分析思路,最终可整理出如前所列的配对四格表

中国人民大学统计学院 24

方法原理

■ 注意

- 主对角线上两种检验方法的结论相同，对问题的解答不会有任何贡献
- 另两个单元格才代表了检验方法间的差异

■ 假设检验步骤如下：

- H_0 : 两法总体阳性检出率无差别，即 $B = C$
- H_1 : 两法总体阳性检出率有差别，即 $B \neq C$

中国25人民大学统计学院

方法原理

根据 H_0 得 b, c 两格的理论数均为 $T_b = T_c = (b+c)/2$ ，对应的配对检验统计量为：

$$\chi^2 = \frac{(b-c)^2}{b+c}, \quad v=1$$

一般在 $b + c < 40$ 时，需用确切概率法进行检验，
■ mcci 56 35 21 28 或者进行校正。

中国26人民大学统计学院

注意事项

- McNemar 检验只会利用非主对角线单元格上的信息，即它只关心两者不一致的评价情况，用于比较两个评价者间存在怎样的倾向。因此，对于一致性较好的大样本数据，McNemar 检验可能会失去实用价值。
 - 例如对1万个案例进行一致性评价，9995个都是完全一致的，在主对角线上，另有5个分布在左下的三角区，显然，此时一致性相当的好。但如果使用 McNemar 检验，此时反而会得出两种评价有差异的结论来。

中国27人民大学统计学院

配对四格表资料的 χ^2 检验

McNemar 检验 (McNemar's test)

例： 两种血清学检验结果比较

	甲 法		合计
	+	-	
+	80 (a)	10 (b)	90
-	31 (c)	10 (d)	41
合计		111	20
			131

 $H_0: B = C$ $H_1: B \neq C$ $\alpha = 0.05$

$$\chi^2 = \frac{(b-c)^2}{b+c}, \quad v=1$$

当 $b+c \geq 40$ 时可不校正，而 $b+c < 40$ 时则一定要校正。本例 $b+c = 10+31 = 41 > 40$ ，不需作连续性校正，计算得

$$\chi^2 = \frac{(10-31)^2}{10+31} = 10.76, \quad v=1$$

中国28人民大学统计学院

```
> ex=matrix(c(80,10,31,10),2,2)
> chisq.test(ex)
Pearson's Chi-squared test with Yates' continuity correction
data: ex
X-squared = 2.8817, df = 1, p-value = 0.08959
> mcnemar.test(ex)
McNemar's Chi-squared test with continuity correction
data: ex
McNemar's chi-squared = 9.7561, df = 1, p-value = 0.001787
```

中国29人民大学统计学院

序和分布的识别

■ 从一般意义上，社会生活不能没有秩序：

- 公务卡购票
- 安检
- 登机
- 享受飞翔的自由

■ 稳定与秩序的辨别：

- 稳定是被动的，秩序是主动的；
- 稳定是静态的，秩序是动态的；
- 稳定是不主张激活的，秩序则是与活力兼容的。

中国30人民大学统计学院

秩序是什么？

- 回想一个随机变量的秩是怎样定义的？
- 秩是独立随机变量向量的一个特征，与**样本量n**有关
— 秩与**分布**分位数的对应关系：

$$q = r / (n + 1)$$

$$q = \int_{-\infty}^{m_q} p(x) dx$$

- 如果数据的分布不知道怎么办？
- 一个随机变量的秩是怎样定义的？

中国人民大学统计学院

问题：A和B两组病人治疗效果是否相同

例子：

组别	疗效				合计
	痊愈	显效	好转	无效	
治疗组(中医)	68	26	15	3	112
对照组(西医)	737	388	25	5	1155

两组病人：治疗组与对照组；疗效：痊愈、显效、好转、无效
特点：有一个分类是按等级分组的。

两分类数据，其中一个分类变量是分类变量；另一个变量是顺序变量；称为单向有序分组数据

关心的问题：各等级的比例是否相同，各不同的组是否存在整体的优劣之分

中国人民大学统计学院

6.6 Ridit检验

对于有序分类变量，采用卡方检验方法不能考虑数据的有序性质。为此，对于单向有序问题可考虑**Ridit分析**。

Ridit检验法的原理：取一个样本数较多的组或者将几组数据汇总成为参照组，根据参照组的样本结构将原来各组响应数变换为参照得分：Ridit得分，利用变换以后的Ridit得分进行处理之间的强弱比较。标准组 $\bar{R}=0.5$ ，其他各对比组均按标准组的各等级R值计算其平均 \bar{R} ，对比组 \bar{R} 在0-1之间波动，最后通过假设检验做出结论

行向量A表示不同组合组，列向量B为顺序尺度变量，假设 $B_1 < L < B_s$ ， O_{ij} 表示对应格子的响应频数。

假设检验问题：

$$H_0: A_i, L, A_j \text{ 之间没有强弱顺序} \leftrightarrow H_1: \text{至少一对 } A_i \neq A_j$$

中国人民大学统计学院

顺序强度计算步骤

各顺序级别 R_j 计算表						
步骤	B_1	B_2	...	B_s	合计	
A_1	O_{11}	O_{12}	...	O_{1s}	$O_{1..}$	
\vdots	\vdots	\vdots	...	\vdots	\vdots	
A_r	O_{r1}	n_{r2}	...	O_{rs}	$O_{r..}$	
总和	$O_{..1}$	$O_{..2}$...	$O_{..s}$	$O_{..}$	
(1)	$H_1 = \frac{1}{2}O_{..1}$	$H_2 = \frac{1}{2}O_{..2}$	$H_j = \frac{1}{2}O_{..j}$	$H_s = \frac{1}{2}O_{..s}$		
(2)	0	$C_2 = \sum_{k=1}^1 O_{..k}$	$C_j = \sum_{k=1}^{j-1} O_{..k}$	$C_s = \sum_{k=1}^{s-1} O_{..k}$		
(3)	N_1	N_2	$N_j = H_j + C_j$	N_s		
(4)	R_1	R_2	$R_j = \frac{N_j}{O_{..}}$	R_s		

(5) 将 R_j 的值按照 O_{ij} 占 O_j 的权重新配置第 i, j 位置的 Ridit 得分：
 $R_{ij} = \frac{O_{ij}}{O_{..j}} R_j$.

(6) 计算第 i 处理 (类) 的 Ridit 得分： $R_i = \sum_{j=1}^s R_{ij}$ 这些 Ridit 得分的期望为 0.5。

两组检验

■ 检验问题：

H_0 : 对照组的 $\bar{R}=0.5$

H_1 : 对照组的 $\bar{R} \neq 0.5, \alpha=0.05$.

计算标准组 Ridit 值 \bar{R} 及标准差

等级	频数	累计频数	频数 / 2	(5)		R 值
				(4)	= (3) + (4)	
(1)	(2)	下移一行	(3)	(4)	(3) + (4)	(5) / 总例数
无效	760	0	380	380	0.114	
好转	1870	760	935	1695	0.509	
显效	670	2630	335	2965	0.890	
控制	30	3300	15	3315	0.995	
合计	3330	—	—	—	—	

中国人民大学统计学院

\bar{R} 及标准差计算公式：

$$\bar{R} = \frac{\sum O_{ij} R_j}{n}, \quad S_R = \sqrt{\frac{\sum O_{ij} R_j^2 - (\sum O_{ij} R_j)^2}{n-1}}$$

表3： Ridit 均值和标准差计算表

等级	R 值	O_{ij}	$O_{ij} R_j$	$O_{ij} R_j^2$
无效	0.114	760	86.64	9.87696
好转	0.509	1870	951.83	484.48147
显效	0.890	670	596.30	530.70700
控制	0.995	30	29.85	29.70075
合计	—	3330	1664.62	1054.76618

本例：

$$\bar{R}_{\text{标准}} = \frac{1664.62}{3330} = 0.5, \quad S_R = \sqrt{\frac{1054.76618 - (1664.62)^2}{3330-1}} = 0.2586$$

中国人民大学统计学院

■ 对照组平均Ridit值计算:

—以对照组各级频数与相应的Ridit得分进行加权平均，得到平均R

$$\bar{R}_{\text{中医}} = \frac{9 \times 0.114 + 51 \times 0.509 + 21 \times 0.890 + 13 \times 0.995}{94} = 0.624$$

■ 计算标准误：样本标准误以标准组的标准差除以样本例数的平方根

$$S_{\bar{R}} = \frac{S_R}{\sqrt{n}} = \frac{0.2586}{\sqrt{94}} = 0.027$$

■ 计算 \bar{R} 的可信区间 $\bar{R} \pm u_{\alpha} S_{\bar{R}}$ $0.624 \pm 1.96 \times 0.027$

■ 95%置信区间是(0.571, 0.677)，不包括0.5，结论为差异显著，因此可以认为两种治疗疗效不同

中国人民大学统计学院

Ridit得分定义

假设顺序类别B中第j类的边缘分布是 $P_{j,i}$, $j=1, \dots, s$, 那么第j类的顺序强度(Ridit得分)定义如下：

$$\begin{aligned} r_j &= \sum_{k=1}^{j-1} p_{j,k} + \frac{1}{2} p_{j,j}, \quad j = 2, \dots, s \\ &= \frac{F_{j-1}^B + F_j^B}{2} \end{aligned}$$

其中

$$F_j^B = \sum_{k=1}^j p_{j,k}, \quad j = 2, \dots, s.$$

在实际计算中用样本估计

中国人民大学统计学院

计算实例

```
ori=c(20,30,25,44,24,26,16,18)
ori1=ori/2
ori2=sum(ori)
ori3=c(0,ori)
ori4=cumsum(ori3)[1:length(ori)]
ori5=(ori1+ori4)/ori2
ori6=ori*ori5
ori7
now1=c(4,8,3,4,1,0,0,0)
sumnow=sum(now1)
sum(now1*ori5)/sum(now1)
cor(now1,ori)
```

中国人民大学统计学院

多组检验

H_0 : A_1, \dots, A_r 之间没有强弱顺序

$\leftrightarrow H_1$: 至少存在一对 A_i, A_j , 使得 $A_i \neq A_j$ 成立.

根据计算的 R 构造检验统计量：

$$W = \frac{12O_-}{(O_- + 1)T} \sum_{i=1}^r O_i (R_i - 0.5)^2$$

其中 T 为打结校正因子

当大样本时, T 值接近于1, 从而检验统计量简化为:

$$W = 12 \sum_{i=1}^k O_i (R_i - 0.5)^2$$

在零假设情况下, W 近似服从 $\chi^2_{(k-n)}$ 分布, 当 W 过大或者过小时, 可考虑拒绝零假设. 近似的置信区间 $\bar{R}_i \pm 1/\sqrt{30_i}$

中国人民大学统计学院

例6.4

例 6.4: 表 6.8 是用头针治疗瘫痪 800 例的疗效分析, 不同病因的疗效可以不一样, 究竟哪一种病因所引起的瘫痪用头针的治疗效果最佳, 哪些次之, 哪些最差, 是医务人员希望数据回答的问题.

表 6.8. 头针治疗瘫痪 800 例的疗效分析

组别	总数	基本痊愈	显效	有效	无效	恶化	死亡
1、脑血栓形成及后遗症	500	190	123	162	24	1	0
2、脑出血及后遗症	132	9	38	73	11	0	1
3、脑栓塞及后遗症	59	20	13	20	6	0	0
4、颅内损伤及后遗症	54	4	12	33	5	0	0
5、急性感染性多发性神经炎	10	4	2	3	1	0	0
6、脊髓疾病	6	1	3	0	2	0	0
总病例数	800	232	202	311	53	1	1

中国人民大学统计学院

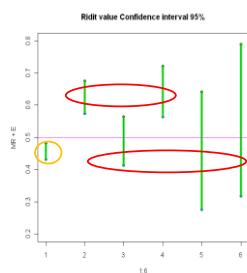
表 6.9. 头针治疗瘫痪 800 例疗效的 Ridit 计算步骤

步骤 \ 级别	基本痊愈	显效	有效	无效	恶化	死亡
(I) (病例数总计)	232	202	311	53	1	1
(II) (病例数 $\times 1/2$)	116	101	155.5	26.5	0.5	0.5
(III) 累积	0	232	434	745	798	799
(II)+(III)	116	333	589.5	771.5	798.5	799.5
$R = \frac{\text{II}+\text{III}}{800}$	0.145	0.416	0.737	0.964	0.998	0.999
合计	33.64	84.082	229.168	51.11	0.998	0.999

中国人民大学统计学院

解答

等级	脑血栓形成及后遗症疗效结果的		
	(1)	(2)	(3)
I	194	0.145	28.130
II	134	0.416	55.774
III	182	0.737	134.11
IV	28	0.964	26.992
V	1	0.998	0.998
VI	0	0.999	0
合计	500		246.10

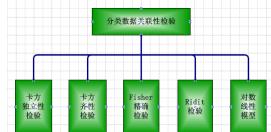


得出 95% 可信限为 0.4564367 ± 0.02 ，由于组的治疗效果对总数 800 例的效果来讲较好。

中国人民大学统计学院

本章要求

- 掌握分类数据的独立性研究方法；
- 区分分类数据的独立性和齐性检验的异同；
- 掌握Fisher检验与卡方检验的应用条件的异同；
- 了解Ridit方法和应用；
- 了解对数线性模型和卡方检验的异同；
- 熟练应用R中的相关命令学习如上方法。



中国人民大学统计学院