

·科研方法专题·

# 如何正确运用 $\chi^2$ 检验——高维表资料 统计分析方法概述

胡纯严<sup>1</sup>, 胡良平<sup>1,2\*</sup>

(1. 军事科学院研究生院, 北京 100850;

2. 世界中医药学会联合会临床科研统计学专业委员会, 北京 100029

\*通信作者: 胡良平, E-mail: lphu927@163.com)

**【摘要】** 本文目的是介绍高维表资料的种类及其对应的统计分析方法。基于结果变量的资料类型, 常见的高维表资料可分为以下三类, 即结果变量为二值变量、多值名义变量和多值有序变量。高维表资料的统计分析方法主要有两大类, 第一类为广义差异性分析, 内容包括“加权 $\chi^2$ 检验”“CMH $\chi^2$ 检验”和“Meta分析”; 第二类为回归分析, 内容包括“对数线性回归模型分析”“Logistic回归模型分析”“Probit回归模型分析”和“离散选择模型分析”。

**【关键词】** 加权 $\chi^2$ 检验; CMH $\chi^2$ 检验; Meta分析; 离散选择模型

中图分类号: R195.1

文献标识码: A

doi: 10.11886/scjsws20210514003

## How to use $\chi^2$ test correctly——the overview of the statistical analysis methods for the data of a multiway table

Hu Chunyan<sup>1</sup>, Hu Liangping<sup>1,2\*</sup>

(1. Graduate School, Academy of Military Sciences PLA China, Beijing 100850, China;

2. Specialty Committee of Clinical Scientific Research Statistics of World Federation of Chinese Medicine Societies, Beijing 100029, China

\*Corresponding author: Hu Liangping, E-mail: lphu927@163.com)

**【Abstract】** The purpose of this article was to introduce the types of a multiway table data and their corresponding statistical analysis methods. Based on the data types of the result variables, common high-dimensional table data could be divided into the following three categories, namely, the high-dimensional table data with binary variables, multi-valued nominal variables and multi-valued ordinal variables as the result variables. There were two main categories of the statistical analysis methods for the multiway table data. The first category was the generalized difference analysis, in which the contents included "weighted  $\chi^2$  test" "CMH  $\chi^2$  test" and "Meta analysis", the second category was the regression analysis, in which the contents included "log linear regression model analysis" "Logistic regression model analysis" "probit regression model analysis" and "discrete choice model analysis".

**【Keywords】** Weighted  $\chi^2$  test; CMH  $\chi^2$  test; Meta analysis; Discrete choice model

在医学资料中, 结果变量为定性变量的情形很常见。最常见的有如下3种情形: ①结果变量为二值变量, 例如“死亡与存活”“治愈与未治愈”和“复发与未复发”; ②结果变量为多值有序变量, 例如“治愈、显效、好转、无效、死亡”和“优、良、中、差”; ③结果变量为多值名义变量, 例如某种基因的类型为“AA、AB、BB”, 某种疾病的类型为“慢性、亚急性、急性”。当仅考察一个原因变量时, 收集到的资料常被整理成二维列联表(简称为二维表)形式<sup>[1-2]</sup>; 当考察的原因变量的个数 $\geq 2$ 时, 收集到的资料常被整理成高维列联表(简称为高维表)形式(参见本文中的表1~表4)。分析高维表资料的统计方法主要有两大类, 第一类为广义差异性分析, 第二类为回归分析。本文将概括介绍高维表资料的种类和有关

实例及其相应的统计分析方法。

### 1 高维表资料的种类及实例

#### 1.1 二值结果变量的高维表资料及其实例

**【例1】**文献[3]呈现了如下资料, 为研究阿司匹林对心血管事件发生的预防作用, 研究者收集了满足要求的7项临床随机对照试验资料, 见表1。

#### 1.2 多值有序结果变量的高维表资料及其实例

**【例2】**假设某研究者为了研究“甲、乙两种治疗方法对不同病程和不同病情的某病患者的治疗效果”, 收集到如下资料, 见表2。

#### 1.3 多值名义结果变量的高维表资料及其实例

**【例3】**假设某研究者为了研究“细胞分化程度

和细胞染色与恶性肿瘤组织类型之间的关系”,收集到如下资料,见表3。

表1 阿司匹林预防心肌梗死后死亡的7项随机对照试验研究结果

研究编号	观察人数(死亡人数)	
	阿司匹林组	安慰剂组
S1	615(49)	624(67)
S2	758(44)	771(64)
S3	32(102)	850(126)
S4	317(32)	309(38)
S5	810(85)	406(52)
S6	2267(246)	2257(219)
S7	8578(1570)	8600(1720)

表2 甲、乙两种治疗方法对不同病程和不同病情的患者治疗效果

治疗 方法	病程	病情	例 数					合计
			疗效:	治愈	显效	好转	无效	
甲	短	轻	50	46	37	12	145	
		重	42	35	32	23	132	
	长	轻	37	30	28	14	109	
		重	31	24	25	38	118	
乙	短	轻	45	49	44	16	154	
		重	38	43	39	22	142	
	长	轻	29	38	34	19	120	
		重	22	33	30	28	113	

注:该例为假设资料

表3 细胞分化程度和细胞染色与恶性肿瘤组织类型之间的关系

分化程度 (X <sub>1</sub> )	细胞染色 (X <sub>2</sub> )	各组织类型(Y)的例数		
		鳞癌 (Y=1)	腺癌 (Y=2)	大细胞癌 (Y=3)
I级 (X <sub>1</sub> =1)	阳性(X <sub>2</sub> =1)	10	17	26
	阴性(X <sub>2</sub> =2)	5	12	50
II级 (X <sub>1</sub> =2)	阳性(X <sub>2</sub> =1)	21	17	26
	阴性(X <sub>2</sub> =2)	16	12	36
III级 (X <sub>1</sub> =3)	阳性(X <sub>2</sub> =1)	15	15	16
	阴性(X <sub>2</sub> =2)	12	12	20

#### 1.4 特殊的高维表资料及实例(简称为“人-时间数据”)

【例4】某研究探讨乙型肝炎病毒(HBV)感染对健康的影响,在原发性肝癌高发区江苏省海门市进行前瞻性队列研究,对研究对象进行流行病学调查,调查结果见表4。

表4 1993年-2003年调查人群的死亡情况

性 别	是否暴露	病例数	人年数
男性	是	1642	88528
	否	2854	529006
女性	是	422	50709
	否	531	251555

【说明】之所以说表4资料具有特殊性,是因为表中各行上除了提供“病例数”之外,还提供了“人年数(即各组中全部受试者所经历的年数之合计值)”,而不是“阴性例数”,也不是“总例数”。分析表4资料,需要对“人年数”进行特殊处理,因篇幅所限,本文不予赘述,可参阅文献[4]。

## 2 分析高维表资料的两类统计分析方法简介

### 2.1 两类统计分析方法概述

高维表资料的统计分析方法主要有两大类,第一类为广义差异性分析,内容包括“加权 $\chi^2$ 检验”“CMH $\chi^2$ 检验”和“Meta分析”;第二类为回归分析,内容包括“对数线性回归模型分析”“Logistic回归模型分析”“Probit回归模型分析”和“离散选择模型分析”。这两类分析方法的区别在于:第一类方法是将多因素降维成单因素问题,属于“基于分层后单个检验统计量的构造及实现”,其结果比较单一;而第二类方法是直接构建定性因变量依赖多因素及其交互作用项变化的回归模型,并采用多种复杂的统计分析方法估计和检验模型中的参数,其结果比较丰富,而且可以更加全面地挖掘资料所蕴含的信息。

### 2.2 广义差异性分析方法

#### 2.2.1 加权 $\chi^2$ 检验

在分析二维表资料时,为了检验表中两属性变量之间是否独立,可采用Pearson's $\chi^2$ 检验、校正的Pearson's $\chi^2$ 检验和似然比 $\chi^2$ 检验。然而,在分析高维表资料时,以上方法均不能直接使用,需要按一个定性变量的各水平或多个定性变量的水平组合进行分层,当各层都是“2×2表资料”时,就可按特定的公式求出各层的权重系数,并进行“加权合并计算”,这就是“加权 $\chi^2$ 检验<sup>[5]</sup>”。

#### 2.2.2 CMH $\chi^2$ 检验

在分析二维表资料时,CMH $\chi^2$ 检验实际上包含了三种检验,即“两属性变量之间的独立性检验( $H_0$ :一般关联)”“两有序变量之间的相关性检验( $H_0$ :非零相关)”和“定性原因变量各水平下定性结果变量的平均秩之间的差异性大小的秩和检验( $H_0$ :行评分均值差异)”;而在分析高维表资料时,首先要对资料进行分层,再进行“合并计算”。CMH $\chi^2$ 检验的结果与前面提及的三种检验结果类似,具体地说,若分层后,各层都是“2×2表资料”

时,三种检验结果是完全相同的;若分层后,各层都不是“2×2 表资料”时,三种检验结果中,“ $H_1$ :非零相关”与“ $H_1$ :行评分均值差异”的检验结果相同,而“ $H_1$ :一般关联”的检验结果与前两种的检验结果是不同的<sup>[6]</sup>。

### 2.2.3 Meta 分析

对三维表资料进行 Meta 分析的任务有以下 4 项:①弄清定性资料来自队列研究设计还是病例对照研究设计。②选定拟分析的效应指标,例如,队列研究设计时,其效应指标有“相对危险度( $RR$ )”或“危险率差( $RD$ )”;病例对照研究设计时,其效应指标有“优势比( $OR$ )”。③检验各层(即各研究项目)的“2×2 表资料”之间是否满足齐性。具体地说,对于队列研究设计资料而言,就是检验各层“相对危险度( $RR$ )”之间是否相等或各层“危险率差( $RD$ )”之间是否相等;而对于病例对照研究设计资料而言,就是检验各层“优势比( $OR$ )”之间是否相等。④计算“合并后资料”的“效应指标( $RR$  或  $RD$  或  $OR$ )”的估计值及其置信区间。在进行前述两步计算时,都必须依据“齐性检验”结果来选择具体方法。

传统算法体系的解决方案:在常规的统计学教科书<sup>[3,7-8]</sup>和用于 Meta 分析的统计软件(例如 Review Manager 软件<sup>[9]</sup>)中,都采取如下策略:第一步,针对不同的“效应指标[ $(RR$  或  $\ln RR$ ) 或  $RD$  或  $(OR$  或  $\ln OR)$ ”构造不同的检验统计量  $Q$ ,检验各层 2×2 表资料是否满足齐性要求;第二步,若“分层 2×2 表资料”满足齐性要求,则采取基于“固定效应模型”导出的公式进行特定效应指标估计和置信区间估计,若“分层 2×2 表资料”不满足齐性,则采取基于“随机效应模型”导出的公式进行特定效应指标估计和置信区间估计。

SAS 算法体系的解决方案:在 SAS/STAT 的 FREQ 过程中<sup>[6]</sup>,只出现了关于“各层优势比( $OR$ )”齐性检验的方法,没有给出关于“相对危险度( $RR$  或  $\ln RR$ )”或“危险率差( $RD$ )”齐性检验的方法。优势比齐性检验的具体方法有以下四种<sup>[6]</sup>:“Breslow-Day 检验”“ $Q$  检验”“计算  $F$  度量统计量及其 95% 置信区间”和“Zelen's 精确检验”。在 SAS/STAT 的 FREQ 过程中<sup>[6]</sup>,没有明确提及“固定效应模型”与“随机效应模型”的概念,只要在“tables 语句”中增加了选项“CMH”,于是,在 SAS 输出结果中,就会输出“普通优比和相对风险”(或称为“共同优比和相

对风险”)的计算结果,具体内容如下所示:

普通优比和相对风险				
统计量	方法	值	95% 置信限	
优比	Mantel-Haenszel	0.7638	0.6475	0.9010
	logit	0.7642	0.6477	0.9016
相对风险 (第 1 列)	Mantel-Haenszel	0.7865	0.6788	0.9114
	logit	0.7882	0.6803	0.9133
相对风险 (第 2 列)	Mantel-Haenszel	1.0279	1.0106	1.0455
	logit	1.0278	1.0110	1.0448

在上面输出的结果中,第 1 列为“统计量”,有“优比”和“相对风险”两种,相对风险又分为两种计算结果,分别基于“分层 2×2 表”的“第 1 列”和“第 2 列”计算所得。若研究者将自己所关心的结局(例如:死亡)放置在表中第 1 列上,就看“相对风险(第 1 列)”所在的行;否则,就看“相对风险(第 2 列)”所在的行。无论是哪一种统计量的估计值和置信区间,SAS 都基于两种方法(即“校正的 Mantel-Haenszel 法”与“校正的 logit 法”)进行计算并输出相应的结果。通过比较发现,它们可以被视为基于“固定效应模型”计算的“估计值及 95% 置信区间”。

下面输出结果中的“精确置信限”可以被视为基于“随机效应模型”计算的“共同优比估计值及 95% 置信区间”。

共同优比	
Mantel-Haenszel 估计	0.7638
精确置信限	
95% 置信下限	0.6456
95% 置信上限	0.9043

值得一提的是,在 SAS/STAT 的 FREQ 过程中,尚未给出与“共同相对危险度(即按分层因素进行合并计算的相对危险度)”对应的精确检验方法,也就是说,当对队列研究设计高维表资料进行 Meta 分析时,若“分层 2×2 表”资料不满足齐性要求时,需要基于随机效应模型导出的公式并借助 SAS 语言编程实现完整的计算<sup>[10]</sup>。

在使用 SAS/STAT 的 FREQ 过程中,只要在“tables 语句”中增加了选项“commonriskdiff(test= mh cl=(k mh mr score newcombe newcombemr))”,于是,SAS 输出结果就会呈现基于 6 种算法得到的“共同危险率差( $RD$ )”的估计值及 95% 置信区间:

方法	普通风险差值置信限		
	值	标准 误差	95%置信限
Klingenberg	-0.0247		-0.0399 -0.0095
Mantel-Haenszel	-0.0247	0.0077	-0.0399 -0.0095
最小风险	-0.0247	0.0076	-0.0397 -0.0098
Newcombe	-0.0247		-0.0400 -0.0095
Newcombe(MR)	-0.0247		-0.0400 -0.0095
汇总评分	-0.0252	0.0076	-0.0402 -0.0102

列 1 (b = 1)

在上面的输出结果中,第 1 列是 6 种计算方法的名称,第 2 列为普通风险率差(RD)的估计值,最后 2 列为其 95% 置信区间的下限值与上限值。其中,最后一行上的“汇总评分法”也叫做“General variance-based 法”<sup>[7]</sup>。在这 6 种方法中,哪些是与“固定效应模型”对应的方法、哪些是与“随机效应模型”对应的方法,有待深入研究。

### 2.3 回归分析

#### 2.3.1 对数线性回归模型

对数线性回归模型不仅可以解决  $\chi^2$  检验所能解决的变量间是否存在关联的问题,还可以解决  $\chi^2$  检验难以分析的多个变量间交互效应的问题。其分析过程是:先构建列联表中各网格中频数的对数(设为因变量)与多个分类变量(视为自变量)间关系的模型,然后用一定的统计方法(常用加权最小二乘方法和最大似然方法估计模型中的参数,并使用迭代法进行计算,如 Newton-Raphson 迭代法)以实际频数拟合模型、估计模型中的参数,并进行参数的假设检验。

#### 2.3.2 Logistic 回归模型

依据定性结果变量的不同类型,Logistic 回归模型有 3 种,即二值结果变量的一般多重 Logistic 回归模型(包括配对设计资料和非配对设计资料两种情形)、多值有序结果变量的累计多重 Logistic 回归模型和多值名义结果变量的扩展(或称为多项)多重 Logistic 回归模型。在前述的几种情形下,依据资料的实际情况,还可以将它们分别扩展成为“带随机效应的多重 Logistic 回归模型”<sup>[6]</sup>和/或“多水平多重 Logistic 回归模型”<sup>[11]</sup>。

#### 2.3.3 Probit 回归模型

Logistic 回归模型与 Probit 回归模型都是用于分

析定性(二值或多值的)响应变量与自变量之间的关系。它们之间最大区别在于:Probit 回归分析中响应变量不再是二值变量,而是介于 0~1 之间的百分比变量。Probit 回归分析中采用的关联函数为 Probit 函数,响应变量取值为 1 的概率如式(1)所示:

$$P(y = 1|x) = \Phi(\beta_0 + \beta_1 x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\beta_0 + \beta_1 x} e^{-\frac{t^2}{2}} dt$$

$$= PROBNORM(\beta_0 + \beta_1 x) \quad (1)$$

这个函数实际上就是标准正态分布曲线下分位数函数  $u=PROBIT(P)$  的反函数。式(1)中的  $\beta_0 + \beta_1 x$  就相当于这里的  $u$ 。在医学研究中,此回归模型常用于估计药物或毒物的半数致死量<sup>[6]</sup>。

#### 2.3.4 离散选择模型

统计学家在“效用最大化”的假设之下推导出离散选择模型。依据结果变量的表现形式,离散选择模型可分为以下两类。

第一类,当结果变量为有序变量(也被称为“偏好评分值”)时,此时的离散选择模型就是“结合分析中的回归模型”<sup>[10]</sup>,见式(2):

$$Y = a + \sum vx \quad (2)$$

在式(2)中, $Y$ 表示某种属性组合下被评对象的总效用,即轮廓的总效用。 $a$ 为截距, $v$ 为属性变量各水平的分值效用, $x$ 为取值为 0 或 1 的哑变量,当它代表的属性水平出现,则  $x=1$ ,否则  $x=0$ 。

若模型中属性水平的分值效用的差值(最大效用与最小效用之差)越大,则该属性的相对重要性越高。一般用百分比的形式来描述各属性的重要性,见式(3):

$$W_j = \frac{\max(v_j) - \min(v_j)}{\sum_{j=1}^m [\max(v_j) - \min(v_j)]} \times 100\% \quad (3)$$

在式(3)中, $m$ 表示属性个数, $W_j$ 表示第  $j$  个属性的相对重要性, $\max(v_j)$ 和  $\min(v_j)$ 分别表示第  $j$  个属性各水平中最大和最小的分值效用。

第二类,当结果变量为多选一(即从多项被选项目中选择一项,选中的项标记为 1,其他未被选中的项一律标记为 0)时,此时的离散选择模型(可进一步划分为“Logit 模型”“Nested logit 模型”和“Probit 模型”)比较复杂<sup>[6]</sup>,限于篇幅,不予赘述。

以上两类模型的适用场合如下:一类物品是否被顾客所青睐,取决于其自身多个属性变量的水平组合以及顾客自身的条件和偏好。例如,假设考虑小轿车的三个属性:车身(分为长、短)、耗油量(分

为多、少)、价格(分为高、低),总共有 $2 \times 2 \times 2 = 8$ 种型号的小轿车可供顾客选择。让某位顾客来挑选时,他或她有两种表达意愿的方式:其一,依次给这 8 种型号的小轿车打一个“分值(1~8分)”,分值越大,代表顾客越喜欢。此时,可选择前述提及的第一类离散选择模型;其二,仅从这 8 种型号的小轿车中选择一种,但参与选择的顾客人数至少应大于 8,此时,可选择前述提及的第二类离散选择模型。

### 3 讨论与小结

#### 3.1 讨论

处理高维表资料时,人们常会犯以下两种错误。

其一,将高维表资料简单地压缩成二维表资料,并直接对其进行统计分析,这样做很容易得出错误的结论。例如,采用 CMH  $\chi^2$  检验分析一个关于“A、B 两个诊所护理量多和护理量少所对应的婴儿死亡率的资料<sup>[12]</sup>”,所得结果如下:共同相对危险度为  $RR=1.1078$ ,其 95% 置信区间为  $[0.3996, 3.0707]$  (Mantel-Haenszel 法)、 $[0.3980, 3.0662]$  (logit 法)。因置信区间包含 1,说明护理量少与护理量多的婴儿死亡率接近相等;若对该资料中的 A、B 两个诊所进行简单合并,得到的四格表资料如下:

	死亡例数	存活例数
护理量少	20	373
护理量多	6	316

用 CMH  $\chi^2$  检验分析上述简单合并后的四格表资料,得到的结果如下:

相对危险度为  $RR=2.7311$ ,其 95% 置信区间为  $[1.1100, 6.7198]$  (Mantel-Haenszel 法)、 $[1.1100, 6.7198]$  (logit 法)。因置信区间不包含 1,说明护理量少与护理量多的婴儿死亡率之间的差别具有统计学意义,前者的死亡率为 5.35%、后者的死亡率为 1.90%。显然,两个死亡率之间的差距被人为地夸大了。究其原因,不难发现:诊所 A 与诊所 B 的四格表资料之间不满足齐性,而且诊所 B 中“护理量多”的人数(25 人)比诊所 A 中“护理量多”的人数(297 人)少了很多。以致于简单合并后的资料中,原本死亡率高(8.00%)的诊所 B 中“护理量多”的那一行数据在合计中的“贡献或权重”很小,从而导致“护理量多”的合计栏中婴儿死亡率“下降”(这可能是一种假象)了很多。

其二,采用回归模型(对数线性模型除外)分析高维表资料时,人们常忽略因素之间的交互作用

项。在使用 Logistic 回归模型和 Probit 回归模型时,使用者很少会把因素之间的交互作用项纳入回归模型中,因为统计学教科书中几乎都忽视了这一点。事实上,在有些实际问题中,因素之间的交互作用是不可忽视的,不将其纳入回归模型,可能会降低回归模型对资料的拟合效果。有时,可能会得出不符合实际的结论。

#### 3.2 小结

本文以高维表形式呈现了三种常见的和一种特殊的多因素定性资料及实例,即“二值结果变量的高维表资料及其实例”“多值有序结果变量的高维表资料及其实例”和“人-时间数据及实例”;概括介绍了分析高维表资料的两类统计分析方法,即“广义差异性分析简介”和“回归分析简介”;最后,还讨论了处理高维表资料时常犯的两类错误,即“将高维表资料简单地压缩成二维表资料”和“基于回归模型分析时常忽略因素之间的交互作用项”。

### 参考文献

- [1] 胡纯严,胡良平.如何正确运用 $\chi^2$ 检验——横断面设计四格表资料的 $\chi^2$ 检验[J].四川精神卫生,2021,34(1):48-52.
- [2] 胡纯严,胡良平.如何正确运用 $\chi^2$ 检验——队列设计四格表资料的 $\chi^2$ 检验[J].四川精神卫生,2021,34(1):53-57.
- [3] 万崇华,罗家洪.高级医学统计学[M].北京:科学出版社,2014:391-411.
- [4] 伯纳德·罗斯纳.生物统计学基础[M].孙尚拱,译.北京:科学出版社,2004:648-709.
- [5] 金丕焕.医用统计方法[M].上海:上海医科大学出版社,1993:174-176.
- [6] SAS Institute Inc. SAS/STAT®15.1 user's guide[M]. Cary, NC: SAS Institute Inc, 2018: 1109-1204, 2997-3216, 6007-6303, 7991-8092.
- [7] 方积乾.卫生统计学[M].7版.北京:人民卫生出版社,2012:434-455.
- [8] 方积乾,陆盈.现代医学统计学[M].北京:人民卫生出版社,2002:150-209.
- [9] 赵仲堂.流行病学研究方法与应用[M].2版.北京:科学出版社,2005:545-569.
- [10] 胡良平.面向问题的统计学——(2)多因素设计与线性模型分析[M].北京:人民卫生出版社,2012:389-405,527-536.
- [11] 王济川,谢海义,费舍余.Multilevel Models: Applications Using SAS[M].北京:高等教育出版社,2009:113-176.
- [12] 胡良平.Windows SAS 6.12 & 8.0 实用统计分析教程[M].北京:军事医学科学出版社,2001:326.

(收稿日期:2021-05-14)

(本文编辑:戴浩然)