

# 混淆因素分层分析方法

天津医学院流行病学教研室 武光林

混淆因素调整方法包括分层分析方法、配比方法和多因素分析方法。本文重点讨论混淆因素分层分析常用统计学方法。

## 两暴露水平资料的混淆因素调整方法

应用最广泛的是Mantel-Haenszel检验方法[1~3]，近年来已在国内逐渐应用。下面再介绍另一种应用较为广泛的Woolf方法。

这种方法也建立在分层方法的基础上。把研究的因素（暴露因素）按双分变量或者说按两个暴露水平分析，然后按混淆因素分为K层，形成K个亚组，表1为第*i*亚组 $2 \times 2$ 表的一般形式。

表1 第*i*亚组病例和对照暴露频数

暴露	病例	对照	合计		
应用	年龄组(岁)				
	25~29	30~34	35~39	40~44	45~49
OC	病例	对照	病例	对照	病例
是	4	62	9	33	4
否	2	224	12	390	33
合计	$n_{1i}$	$n_{2i}$	$n_i$		

假定每个 $2 \times 2$ 表亚组的比数比为 $\psi_i$ ，那么调整混淆因素后Woolf比数比为：

$$\hat{\psi}_w = \exp \left[ \sum_{i=1}^k V_i^{-1} \ln \frac{\hat{\psi}_i}{\sum_{i=1}^k V_i^{-1}} \right] \dots \dots \dots \quad 1$$

式中 $V_i = (a_i + c_i) / a_i c_i + (b_i + d_i) / b_i d_i$

假定 $\ln \hat{\psi}_w$ 为近似的正态分布，显著性检验的统计值 $\chi_w^2$ 的计算公式为：

$$\chi_w^2 = W (\ln \hat{\psi}_w)^2 \dots \dots \dots \quad 2$$

式中 $w = \sum_{i=1}^k V_i^{-1}$ ，自由度 $df = 1$ 。

$\hat{\psi}_w$ 的95%可信限为：

$$\hat{\psi}_w, \bar{\psi}_w = \hat{\psi}_w \exp (\pm 1.96 / \sqrt{W}) \dots \dots \dots \quad 3$$

表2是一个心肌梗塞(MI)和口服避孕药(OC)的病例对照研究资料，新近应用OC为暴露因素，按

年龄分层分析MI-OC的关系。应用Woolf方法计算按年龄调整后比数比及其95%可信限 $\hat{\psi}_w = 4.2 (2.51, 6.99)$ ,  $\chi_w^2 = 30.48 (df = 1)$ ；而按Mantel-Haenszel方法计算 $\hat{\psi}_{MH} = 3.97 (2.28, 6.93)$ ,  $\chi_{MH}^2 = 27.97 (df = 1)$ 。可见两种计算方法非常接近，均表明MI-OC有关。但是Woolf方法在计算时有一定的限制。由于公式中涉及到 $V_i$ ，当 $2 \times 2$ 亚表出现0值就不能计算，所以Mantel-Haenszel方法应用更为广泛。

表2 按年龄调整后心肌梗塞和应用口服避孕药的关系

应用	年龄组(岁)				
	25~29	30~34	35~39	40~44	45~49
OC	病例	对照	病例	对照	病例
是	4	62	9	33	4
否	2	224	12	390	33
合计	$n_{1i}$	$n_{2i}$	$n_i$		
	326	233	42	423	37

## 多暴露水平资料混淆因素调整方法

我们前面提到的Mantel-Haenszel检验方法和Woolf方法对混淆因素调整有一个显著的特点，即均建立在 $2 \times 2$ 表的基础上。对于混淆因素可以同时调整几个，而每个混淆因素亦可分为K个水平。但对暴露因素则仅仅是双分的，只能分为两个暴露水平。但是在某些变量与疾病关系分析中，是否存在剂量反应关系是我们需要考虑的重要问题。若按混淆因素分层适当，应当在每个层次内消除了混淆作用。如果粗比数比分析存在剂量反应关系，那么在对混淆因素调整后，暴露因素的这种关系是否继续存在显然是一个需要深入分析的问题。这用前面介绍的方法是不能解决的，而Meittinen提出的相对危险度标准化方法[4]和Mantel提出的扩大的Mantel-Haenszel检验程序[5]恰恰解决了这样一个问题。

**一、标准化相对危险度方法：**如表3，如果我们以参照组为标准进行标准化，那么计算第*i*暴露水平SRR<sub>i</sub>的公式为：

$$\widehat{SRR}_i = \left( \sum_j a_{ij} d_j / C_{ij} \right) / b \quad \dots \dots \dots \quad 4$$

$\Sigma$  表示各层次总和，下标  $ij$  分别表示在第  $i$  水平和第  $j$  层。

表 3 第  $j$  层标准化相对危险度公式中符号意义

层次	组别	危险因素范畴	
		第 $i$ 水平	参照组
第 $j$ 层	病例 对照	$a_{ij}$ $c_{ij}$	$b_{ij}$ $d_{ij}$
合计	病例 对照	$a_i$ $c_i$	$b$ $d$

表 4 的资料是分析产次和乳腺癌关系的病例对照研究。按粗相对危险度 (CRR) 分析发现随着产次的增加对乳腺癌相对危险度降低。为了反映产次和乳腺癌的真正关系，我们通过标准化相对危险度方法控制初产年龄的混淆作用。结果显示：各产次范围的 SRR 均与参照组接近，说明产次与乳腺癌无关联。

表 4 按初产年龄调整后生产次数和乳腺癌的关系

初产年龄 (岁)	组别	生产次数			合计
		1*	2~3	4~9	
<20	病例	2	6	10	18
	对照	24	47	50	121
	合计	26	53	60	139
20~29	病例	36	144	68	248
	对照	129	428	312	869
	合计	165	572	380	1117
≥30	病例	39	47	22	108
	对照	80	144	32	256
	合计	119	191	54	364
总计	病例	77	197	100	374
	对照	233	619	394	1246
	CRR	1.00	0.96	0.77	
	SRR <sub>i</sub>	1.00	0.94	1.14	

\* 参照组

这里我们应用了流行病学常用指标相对危险度。从统计学的角度讲，前面的公式只有应用比数比 (odds ratio) 的概念才普遍适用。所以标准化相对危险度也可以称为标准化比数比。

**二、扩大的 Mantel-Haenszel 检验方法：** 标准化相对危险度的明显好处是比较直观。如上例，经标准化的相对危险度与参照组相比均接近 1，显示产次与乳腺癌的关系是由于初产年龄混淆的结果。如果暴露-疾病之间无关联，调整混淆因素后的 SRR 理论上应该等于 1。但是由于调查资料是样本，存在着机会问题，不可能完全出现这种情况，所以需要做显著性检验。这就是下面介绍的扩大的 Mantel-Haenszel  $\chi^2$  检验方法。

1. 基本公式：假定我们对所研究的因素分层为  $K$  个有序水平，将其按某一变量（混淆变量）分为  $i$  层，即形成  $i$  个  $2 \times K$  表，那么第  $i$  层就形成第  $i$  个  $2 \times K$  表（表 5）。

表 5 第  $i$  个  $2 \times K$  连续表图表说明

	所研究因素水平 $j$						合计
	0	1	2	...	$K-1$		
	$Y_0$	$Y_1$	$Y_2$	...	$Y_{k-1}$		
病例	$A_{0i}$	$A_{1i}$	$A_{2i}$	...	$A_{k-1i}$		$N_{1i}$
对照	$B_{0i}$	$B_{1i}$	$B_{2i}$	...	$B_{k-1i}$		$N_{2i}$
合计	$M_{0i}$	$M_{1i}$	$M_{2i}$	...	$M_{k-1i}$		$T_i$

所研究水平（暴露水平）即以  $j$  表示，分层数以表示，病例和对照分别为  $A_{ji}$  和  $B_{ji}$ ，则下标  $j$  表示水平数，下标  $i$  表示层数， $Y_j$  为暴露水平的标度，规定  $X$  值病例为 1，对照为 0。

① 单一的  $2 \times K$  连续表  $\chi^2$  的计算公式 ( $df=1$ )：

$$\chi^2 = \frac{\left[ \sum_j A_{ji} Y_j - E \left( \sum_j A_{ji} Y_j \right) \right]^2}{V \left( \sum_j A_{ji} Y_j \right)} = \frac{\left[ \sum_j A_{ji} Y_j - \frac{N_{1i}}{T_i} \left( \sum_j M_{ji} Y_j \right) \right]^2}{\frac{N_{1i} N_{2i}}{T_i^2 (T_i - 1)} \left[ \sum_j T_i \sum M_{ji} Y_j^2 - (\sum_j M_{ji} Y_j)^2 \right]} \quad \dots \dots \dots \quad 5$$

此为第  $i$  个  $2 \times K$  表线性趋势的  $\chi^2$  检验公式， $\sum_j A_{ji} Y_j$  为不同暴露水平  $Y_j$  与相应水平病例数相乘的合计数， $E(\sum_j A_{ji} Y_j)$  和  $V(\sum_j A_{ji} Y_j)$  分别表示  $\sum_j A_{ji} Y_j$  的预期值和方差。目的在于检验暴露-疾病二者之间是否存在剂量反应关系。

②  $i$  个  $2 \times K$  连续表总  $\chi^2$  检验公式 ( $df=1$ )：

$$\chi^2_{sum} = \frac{\left[ \sum_i \sum_j A_{ji} Y_i - \sum_i E(\sum_j A_{ji} Y_i) \right]^2}{\sum_i \sum_j V(\sum_j A_{ji} Y_i)}$$

此公式则为按混淆因素分层后暴露-疾病之间剂量反应关系 $\chi^2$ 检验公式。

③暴露水平测量值  $Y_{ji}$ : 可以把  $Y_j$  按照所研究变量的暴露范围中点确定, 如把吸烟按照每天吸烟支数 0、1~10、11~20、21~30、 $\geq 31$  分层, 那么可以把  $Y_{ji}$  分别定为 0、5、15、25、35。或者让  $Y_{ji}=j$ , 即把  $Y_{ji}$  按 0、1、2、3、4 处理。也可利用  $Y_{ji}$  专用公式, 可参考文献[5]这里不再介绍。

## 2. 基本计算步骤：

单一的 $2 \times K$ 表 $\chi^2$ 检验,

$$\textcircled{1} \sum_j A_{ji} Y_j$$

$$\textcircled{2} \sum_j M_{ji} Y_i$$

$$\textcircled{3} \sum_j M_{ji} Y_j^2$$

$$④ \frac{N_i}{T_i}$$

$$⑤ \frac{N_{1i}N_{2i}}{T_i^2(T_i - 1)}$$

$$\textcircled{6} E(\sum_j A_{ji} Y_j) = \textcircled{2} \textcircled{4}$$

$$\textcircled{7} V(\sum_j A_{ji} Y_j) = \textcircled{5}(T_i \textcircled{3} - \textcircled{2}^2)$$

$$\textcircled{8} \chi^2 = \frac{(\textcircled{1} - \textcircled{6})^2}{\textcircled{7}}$$

计算*i*个 $2 \times K$ 表的总 $\chi^2$ 值。

$$(\Sigma \textcircled{1} - \Sigma \textcircled{6})^2$$

$$\chi^2_{\text{sum}} = \frac{\sum_i (O_i - E_i)^2}{E_i}$$

应用这些步骤计算起来相当方便。我们仍以表 4 的资料为例。首先确定  $Y_j=j$ , 定为 0、1、2 三个水平, 然后把初产年龄三个层次分别按  $i=1、2、3$  计算单一的  $2 \times K$  表  $\chi^2$  值。例如 在初产年龄 < 20 岁层次内 ( $i=1$ ), 计算:

$$\textcircled{1} \sum_j A_{ji} Y_j = 2 \times 0 + 6 \times 1 + 10 \times 2 = 26$$

$$\textcircled{2} \sum_j M_{ji} Y_j = 26 \times 0 + 53 \times 1 + 60 \times 2 = 173$$

$$\textcircled{3} \sum_i M_{ji} Y_j = 26 \times 0 + 53 \times 1 + 60 \times 2^2 = 293$$

然后按照①~⑧中其它步骤计算  $\chi^2 = 1.47$ 。各层次计算结果列于表 6。

表 6 表4中3个 $2 \times K$ 表主要计算结果

$\sum_i \sum_j A_{ji} Y_{ij}$	$E(\sum_j A_{ji} Y_{ij})$	$V(\sum_j A_{ji} Y_{ij})$	$\chi^2_i$
①	⑥ = ② ④	⑦ = ⑤ ( $T_i$ ③ - ② <sup>2</sup> )	⑧ = $\frac{(① - ⑥)^2}{⑦}$
1 26	22.403	8.820	1.47
2 280	295.731	83.069	2.81
3 91	88.714	33.771	0.15
$\sum_i$	397	406.848	130.660
			-

在此基础上计算 3 个  $2 \times K$  表的总  $\chi^2$  值。

$$\chi^2_{\text{sum}} = \frac{(397 - 406.848)^2}{130.660} = 0.74$$

所以在消除了初产年龄混淆作用之后 $\chi^2$ 值为0.74,  $P>0.05$  ( $df=1$ ), 产次与乳腺癌无关联, 这与前面标准化相对危险度分析结果完全一致。

前面介绍的两种方法均为多暴露水平资料的混淆因素调整方法。和Mantel-Haenszel 检验方法比较, SRR相当于 $\psi_{MH}$ , 但 $\psi_{MH}$ 表示两暴露水平的调整比数比, 而SRR表示和暴露水平0比较的各暴露水平的调整比数比。SRR的主要优点是, 既可以与CRR比较, 也可以看出SRR与暴露水平之间的关系变化。但是在一般情况下需做统计学检验。扩大的Mantel-Haenszel 检验方法相当于 $\chi^2_{MH}$ 。所不同的是,  $\chi^2_{MH}$ 用于检验 $\psi_{MH}$ 是否有显著的统计学关系, 扩大的Mantel-Haenszel 检验方法用于检验按混淆因素分层后暴露-疾病之间是否存在剂量反应关系, 是一种线性趋势 $\chi^2$ 检验方法, 作为统计学推断, 这是一种主要方法。但是作为流行病学分析, 和标化相对危险度方法结合使用可能更全面一些。

## 讨 论

疾病和某些因素之间的关系是非常复杂的。疾病的发病原因往往是多因素的，有关因素和一些无关因素之间又是彼此联系相互影响的。一些混淆因素常常掩盖某些因素与疾病的关系，如果不加控制就不能发现彼此间的真正关系。所以仅对资料进行一般的分析是不够的。

我们上面讨论了Mantel-Haenszel 检验程序及其基础上发展的方法，也介绍了 Woolf 检验方法 Miettinen 标化相对危险度方法。这些方法解决了一个或若干混淆因素同时调整问题，也解决了把暴露水

平分为两个或多于两个水平的分析问题。这些方法是建立在分层分析方法的基础上的。分层分析方法在病例对照研究中得到广泛的应用，同样也适用于队列研究分析[6]。

### 参 考 文 献

1. Mantel N, Haenszel W. Statistical aspects of the analysis of data from retrospective studies. *J Natl Cancer Inst* 1959; 22: 719.
2. Hauck WW. The large sample variance of the Mantel-Haenszel estimator of a common

- odds ratio. *Biometrics* 1979; 35: 812.
3. Schlesselman JJ. *Case-control studies: Design, conduct, analysis*. New York, Oxford University Press, 1982.
4. Miettinen OS. Standardization of risk ratios. *Am J Epidemiol* 1972; 96: 383.
5. Mantel N: Chi-square tests with one degree of freedom extension of the Mantel-Haenszel procedure. *J Am Statist Assoc* 1963; 58: 690.
6. Breslow NE. Elementary methods of cohort analysis. *Int J Epidemiol* 1984, 13: 112.

(本文承蒙耿贯一教授审阅，谨此致谢)

## 一起由侵袭性大肠杆菌引起的食物中毒

北京市西城区卫生防疫站 张志果 杨好施 罗 寒 陆秀娟 马艳华

1986年11月份我市西城区某大学院校，因就餐快点盒饭而导致一起76人食物中毒，经流行病学调查及病原学鉴定，证实为侵袭性大肠杆菌所引起。现报告于下：

**一、流行病学调查：**该校因有在外演出任务，于17点30分晚餐进食快点盒饭。演出人数为80人。进食快点盒饭者76人，其中四人未吃快点盒饭。快点盒饭为不透明塑料包装，内有米饭3~4两，菜为胡萝卜土豆烧牛肉，并有白色熟鸡块。进餐盒饭时，即有感腹泻味，约八小时后，即翌日凌晨1点开始出现症状，进食者，无一幸免，全体出现中毒症状，仅轻重不同而已。其中一人较重者。仅进食四分之一饭盒，即腹泻5~7次。中毒患者中，女性较男性为重，而未进食盒饭的四人，无一人出现症状，在校所有学生职工，也无一人出现症状，全部正常。76位患者经治疗，无一例死亡。

**二、临床症状：**发病开始首先出现头痛、头晕、恶心，继之于腹部脐周出现阵发性腹痛，而后出现腹泻，多者5~7次，一般为3~4次。腹泻呈粘液状

稀便，便镜检，有的可见白细胞。腹部有里急后重感，似菌痢样。无呕吐者；体温正常。

**三、采取样品及实验室检查：**根据中华人民共和国食品卫生检验方法规定进行采样，计剩馀快点盒饭二件，中毒患者大便五份、血二份，送交实验室进行病原菌鉴定，实验室经培养，挑选可凝菌落，进行生化及血清学鉴定：于快点盒饭及中毒患者大便中，同时分离出侵袭性大肠杆菌O<sub>28</sub>acK<sub>7</sub>s和O<sub>112</sub>acK<sub>88</sub>两型侵袭性大肠杆菌，并且作了初期患者血清与恢复期患者血清抗体滴度测定，与O<sub>28</sub>acK<sub>7</sub>s和O<sub>112</sub>acK分离的两型菌株，其抗体滴度分别增长16倍和32倍，证实该两型菌株确属为该次引起食物中毒的病原菌。

**四、小结：**这次发生的食物中毒十分典型。首先人数集中，凡进食快点盒饭者，全部出现中毒症状，而病发时间也集中，未检出其它病原菌。

从本文资料来看，应加强执行有关食品卫生管理法规，尤当认真对盒饭以及熟食肉类的管理，是完全必要的，以保证人民的健康。