

(系列讲座)

现代实用流行病学

第二讲 病例对照研究(续)

章扬熙

[例9] 对例8资料进一步作分层、分级分析，不同性别吸烟量与肺癌关系如表10，试进行分析。

表10 不同性别吸烟量与肺癌的关系

组别		每日吸烟量(支)								合计	
		0		1~		5~		15~			
		0	Y ₀	2.5	Y ₁	10	Y ₂	20	Y ₃		
男	病例	2	a ₁₀ =c ₁	33	a ₁₁	250	a ₁₂	364	a ₁₃	649 M ₁₁ Σa _{1j} Y _j =9862.5	
	对照	27	b ₁₀ =d ₁	55	b ₁₁	293	b ₁₂	274	b ₁₃	649 M ₀₁ ΣN _{1j} Y _j =18410	
	合计	29	N ₁₀	85	N ₁₁	543	N ₁₂	638	N ₁₃	1298 T ₁ ΣN _{1j} Y _j ² =310050	
	OR	1.00		8.10		11.52		17.93			
女	病例	19	a ₂₀ =c ₂	7	a ₂₁	19	a ₂₂	15	a ₂₃	60 M ₁₂ Σa _{2j} Y _j =507.5	
	对照	32	b ₂₀ =d ₂	12	b ₂₁	10	b ₂₂	6	b ₂₃	60 M ₀₂ ΣN _{2j} Y _j =757.5	
	合计	51	N ₂₀	19	N ₂₁	29	N ₂₂	21	N ₂₃	120 T ₂ ΣN _{2j} Y _j ² =11418.75	
	OR	1.00		0.98		3.20		4.21			
SRR		1.00		1.66		3.99		5.52			
SRR95%		1.00		1.16~		2.80~		3.87~			
可信区间				2.90		6.97		9.65			

检验剂量反应关系的总趋势时，可用公式40进行 扩展的X_{M-EXT}检验，得

$$\chi_{M-EXT}^2 = \frac{\left(9862.5 - \frac{649}{1298} \times 18410\right) + \left(507.5 - \frac{60}{120} \times 757.5\right)}{\left[\frac{649 \times 649}{1298^2 (1298-1)} \left(1298 \times 310050 - 18410^2\right) + \frac{60 \times 60}{120^2 (120-1)} \left(120 \times 11418.75 - 757.5^2\right)\right]^{\frac{1}{2}}} = 6.67$$

其界值即u_{0.05}=1.96，u_{0.01}=2.58，P<0.01，说明吸烟量与肺癌有剂量反应关系。于是，可进一步用

$$by = \frac{\left(9862.5 - \frac{649}{1298} \times 18410\right) + \left(507.5 - \frac{60}{120} \times 757.5\right)}{\left(310050 - \frac{18410^2}{1298}\right) + \left(11418.75 - \frac{757.5^2}{120}\right)} = 0.014$$

把不吸烟组与不同吸烟量组比较，求OR，比如男性每日吸5~支组， $OR = \frac{ad}{bc} = \frac{250 \times 27}{293 \times 2} = 11.52$ ，余类

公式41求线性趋势的斜率，即回归系数，得

推。若各层OR一致，可用公式39计算总OR，否则计

本文作者单位：辽宁省卫生防疫站 110005 沈阳市

算标准化率比, 本例男女OR已证明相差大, 应用公式42求SRR, 比如每日吸烟5~支组

$$\left[3.99^{-1} \pm 1.96 \times \frac{\sqrt{2+19}}{\frac{250 \times 27}{293} + \frac{19 \times 32}{10}} \right]^{-1} = 2.80 \sim 6.97$$

余类推, 结果列于表10的末行。从各SRR值显见, 吸烟量越大患肺癌的危险度也越大。

在分析性流行病学的研究中, 常遇到多因素问题, 对于数量较少的多因素问题, 可作析因分析。析因分析是按几个研究因素与各因素水平的一切组合状态情况分组, 以各因素的基准水平为对比点, 计算各状态的OR值, 考察各因素的单一作用与交互影响(加法

$$SRR = \frac{250 \times 27 / 293 + 19 \times 32 / 10}{2+19} = 3.99$$

再用公式43、44求其95%可信区间, 得

模型 $OR_{11} = OR_{10} + OR_{01} - 1$ 与乘法模型 $OR_{11} = OR_{10} \cdot OR_{01}$ 时不存在交互作用), 这种方法直观、简易, 便于应用。

[例10] 对某造船厂工人进行接触石棉、吸烟两因素与肺癌联系的病例对照研究, 结果如表11, 试进行分析。

表中OR、S(lnOR)及OR的95%可信区间是分

表11 接触石棉及吸烟与肺癌的关系

接触石棉史	吸烟史	病例	对照	OR	lnOR	S(lnOR)	OR 95% 可信区间
-	-	50c	203d	1.00	-	-	-
-	+	217	220	4.01	1.3888	0.1187	3.18~5.06
-	++	96	50	7.80	2.0541	0.1880	5.40~11.27
+	-	11	35	1.28	0.2469	0.3527	0.64~2.56
+	+	70	42	6.78	1.9140	0.2074	4.52~10.18
+	++	14	3	18.95	2.9258	0.6401	5.32~65.39

别应用公式29、31、32, 求得。从各OR值看, 吸烟与接触石棉均为肺癌的危险因素, 而且吸烟还有剂量反应关系。接触石棉与吸烟有加法模型的协同作用 [$6.78 > (4.01 + 1.28 - 1)$, $18.95 > (7.80 + 1.28 - 1)$]。但是从总体OR的95%可信限看, 仅接触石棉者OR为0.64~2.56, 说明尚无显著性, 同时接触石棉及吸烟者的OR 95% 可信区间的下限均小于两者单因素OR 95% 可信区间的上限和减一, 也说明不显著, 这很可能是由于分层后, 有的层例数不够的原因, 可改用Logistic模型分析或增加例数作进一步的研究。

配比的病例对照研究统计推断

配比病例对照研究资料应按配比方法进行统计分析, 1:1配比与1:M配比(M>1)资料分析公式也不相同。

一、1:1配比的病例对照研究:

[例11] Sartwell等人研究口服某避孕药史与妇女患血栓栓塞的联系, 从美国五个城市选择15~44岁妇女采用1:1配比方法进行了病例对照研究, 结果如表12, 试进行分析。

表12 口服避孕药与血栓栓塞的关系

病例	对照		共配比数
	有服避孕药史	无服避孕药史	
有服避孕药史	10(a)	57(b)	67(a+c)
无服避孕药史	13(b)	95(d)	108(b+d)
共配比数	23(a+b)	152(c+d)	175(T)

在对比病例与对照口服避孕药史情况的差异，只有b、c有意义，病例服避孕药但对照未服避孕药的配比有57，对病例未服避孕药但对照服避孕药的配比只有13对， χ^2 检验用下式

$$\chi^2 = \frac{(b-c)^2}{b+c} \quad (48)$$

当**+c<40**时，用连续性校正公式为

$$\chi^2 = \frac{(|b-c|-1)^2}{b+c} \quad (49)$$

$$\text{本例 } \chi^2 = \frac{(13-57)^2}{13+57} = 27.66$$

自由度df=1，P<0.01，说明病例与对照服避孕药率有差别，可进而用公式50计算比数比

$$OR = \frac{c}{b} \quad (50)$$

$$\text{本例 } OR = 57/13 = 4.38$$

总体OR的95%可信区间用公式11计算，该公式中 $\chi = \sqrt{\chi^2}$ ， χ^2 值用不作连续性校正的 χ^2 值。本例得

$$4.38 \pm 1.96 / \sqrt{27.66} = 2.53 \sim 7.60$$

以上结果说明，有口服避孕药史与患血栓栓塞有联系，其总体OR在2.53~7.60内的概率为95%。

应用公式51计算AR%

$$AR\% = \frac{c-b}{c} \quad (51)$$

$$V(PAR\%) = \frac{1}{CT^2} \left\{ a(c-b)^2 + \frac{(c^2+ab)^2}{c} + b(a+c)^2 - \frac{(a+c)^2(c-b)^2}{T} \right\} \quad (55)$$

$$PAR\% \pm u\alpha \sqrt{V(PAR\%)} \quad (56)$$

$$\text{本例 } V(PAR\%) = \frac{1}{57^2 \times 175^2} \left\{ 10 \times (57-13)^2 + \frac{(57^2+10 \times 13)^2}{57} + 13 \times (10+57)^2 - \frac{(10+57)^2 \times (57-13)^2}{175} \right\} = 0.00229441$$

PAR%的95%可信区间为

$$0.2955 \pm 1.96 \sqrt{0.00229441} = 0.2016 \sim 0.3894 \\ (20.16\% \sim 38.94\%)$$

这说明在美国该地患血栓栓塞妇女病例中29.55%可归因于服用该避孕药，总体PAR%的95%可信区间为20.16%~38.94%

二、1:M配比的病例对照研究：以1:2配比的实例来说明。

[例12] 吸烟与冠心病联系的1:2配比病例对照研究结果如表13，试进行分析

进行 χ^2 检验，检验假设为两组总体吸烟率相等，

$$\text{本例 } AR\% = \frac{57-13}{57} = 0.7719$$

应用公式52、53计算AR%的方差及100(1- α)%可信区间

$$V(AR\%) = \frac{b(b+c)}{c^2} \quad (52)$$

$$AR\% \pm ua \sqrt{V(AR\%)} \quad (53)$$

$$\text{本例 } V(AR\%) = \frac{13(13+57)}{573} = 0.004914$$

AR%的95%可信区间为：

$$0.7719 \pm 1.96 \sqrt{0.004914} = 0.6345 \sim 0.9093$$

这说明在有口服避孕药史的人群中，由于服用口服避孕药导致患血栓栓塞的占血栓栓塞患者总数的77.19%，总体AR%的95%可信区间为63.45%~90.93%。

应用公式54计算PAR%

$$PAR\% = \frac{(a+c)(c-b)}{CT} \quad (54)$$

$$\text{本例 } PAR\% = \frac{(10+57)(57-13)}{57 \times 175} = 0.2955 \\ (\text{即 } 29.55\%)$$

应用公式55、56计算PAR%的100(1- α)%可信区间

表13 吸烟与冠心病联系的1:2配比资料

病例吸烟史	对照中吸烟史数			合计
	0	1	2	
1	22(n _{1,0})	50(n _{1,1})	22(n _{1,2})	94
0	21(n _{0,0})	34(n _{0,1})	13(n _{0,2})	68
合计	43	84	35	162

设检验水准为0.05，用公式57求 χ^2 值，自由度为1（这是1:M配比资料求 χ^2 值的通用公式）

$$\chi^2 = \frac{\left[\sum_{m=1}^M (M-m+1) n_{1,m-1} - \sum_{m=1}^M n_{0,m} \right]^2}{\sum_{m=1}^M (n_{1,m-1} + n_{0,m}) m (M-m+1)} \quad (57)$$

本例 $M=2, m=1, 2$

$$\begin{aligned} \chi^2 &= [(2-1+1) \times 22 + (2-2+1) \times 50 - \\ &\quad (1 \times 34 + 2 \times 13)]^2 \div [(22+34) \times \\ &\quad 1 \times (2-1+1) + (50+13) \times 2 \times (2- \\ &\quad 2+1)] = 4.86 \end{aligned}$$

自由度 $df=1, \chi^2_{0.05}=3.84, P<0.05$, 拒绝检验假设, 说明吸烟与冠心病有联系。

当(总例数- $n_{1,M}-n_{0,0})<40$ 时, 应用校正 χ^2 公式, 为公式 54 分子未平方前取绝对值后减去 $1/2 (M+1)$ 后再平方, 分母不变。由于 χ^2 检验说明吸烟与冠心病有联系, 可进而用公式 58 计算比数比(OR)

$$OR_{MH} = \frac{\sum_{m=1}^M (M-m+1) n_{1,m-1}}{\sum_{m=1}^M m n_{0,m}} \quad (58)$$

$$\begin{aligned} \text{本例 } OR_{MH} &= \frac{(2-1+1) \times 22 + (2-2+1) \times 50}{1 \times 34 + 2 \times 13} \\ &= 1.57 \end{aligned}$$

总体 OR 的 95% 可信区间仍用公式 11 计算, 本例为 $1.57 (1 \pm 1.96 / \sqrt{4.86}) = 1.05 \sim 2.34$

病例对照研究的 Logistic 回归模型分析

在现代流行病学研究中, 常遇到多种致病因素相互联系、相互制约的复杂病因链, 对其采用选择对象、配比等方法, 化多因素问题为单因素, 则会产生孤立的研究单因素不能认识因素间的交互作用之弊。所以多因素问题宜采用多因素的研究方法, 分层分析仅适用因素较少、样本例数较多的情况, 而且当因素是连续性变量时, 只能用等级分层方法, 从而损失不少信息。有人曾用线性回归模型来研究多个暴露因素与疾病的联系, 但估计的发病率可能出现小于 0 或大于 1 的不合理情况。二十世纪六十年代, 在流行病学领域开始应用了 Logistic 回归模型, 它弥补了 M-H 分层分析法和线性回归的不足, 经过近年的发展, 现已成为分析性流行病学研究中的重要方法。

一、Logistic 回归模型概述: 设影响疾病发病各

的研究因素有 p 个, 即 X_1, X_2, \dots, X_p , 发病概率为 P , Logistic 模型可以表达为

$$P = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p)}} \quad (59)$$

又设 Logit $P = \ln \frac{P}{1-P}$, 即发病率与未发病率的

比数的自然对数, 则 Logistic 模型又可以表达成线性形式

$$\text{Logit } P = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p \quad (60)$$

式中 $\beta_k (k=1, 2, \dots, p)$ 为偏回归系数。

对这些参数的估计, 通常采用最大似然法, 以使 β_k 不限于多元正态分布的假定, 而推广至指数密度族的一些子集, 自变量的类别和分布不受限制, 具有广泛的应用价值。这个计算是应用专用程序在电子计算机上进行的。计算步骤为:

(一) 构造一个似然函数 L , 为了简化计算, 再取其自然对数值 $\ln L$;

(二) 对这个对数似然函数 $\ln L$ 求其各参数 β 的一阶偏导数;

(三) 通常是应用 Newton-Raphson 迭代法, 解下列非线性方程组, 求出满足下列方程组的 $\hat{\beta}_k$, 即为各参数 β_k 的最大似然估计值。

$$\left[\frac{\partial \ln L}{\partial \beta_k} \right]_{\beta=\hat{\beta}} = 0$$

(四) 各参数估计值 $\hat{\beta}_k$ 的方差、协方差矩阵为迭代终止时得到的信息矩阵的逆矩阵, 即目标函数二阶偏导数的负值组成的矩阵的逆矩阵。应用这些信息, 可对 $\hat{\beta}_k$ 进行假设检验和参数的区间估计。

(五) 应用 Logistic 回归模型进行分析, 目的在于把因素效应有显著意义的变量纳入模型之中。通常采用阶梯式配合技术, 即由最简单的模型开始, 直到把所有显著意义的变量全部纳入模型之中, 最后把有显著意义的变量间交互影响项也纳入模型之中。各模型对资料拟合的好坏, 可进行拟合优度检验, 包括直接检验方法和参数的假设检验两类。

1. 直接检验方法: 将每个个体的发病概率估计值从小到大排列, 采用 10 分位分组方法分为 10 组(每组合计人数为 $T/10$) 进行 C 检验或按发病概率 $P (Y=$

$X | X$ 等距分为 10 组(各组段上限依次为 0.1, 0.2, …, 1.0) 进行 H 检验,

$$C = \sum_{k=0}^1 \sum_{j=1}^{10} \frac{(O_{kj} - E_{kj})^2}{E_{kj}} \quad (61)$$

$$O_{1L} = \sum_{j \in D_1} Y_j, \quad O_{0L} = \sum_{j \in D_1} (1 - Y_j) \quad (62, 63)$$

$$E_{1L} = \sum_{j \in D_1} P(Y=1 | X) \quad (64)$$

$$E_{0L} = \sum_{j \in D_1} (1 - P(Y=1 | X_j)) \quad (65)$$

式中 O_{1L} 为实际病例数, O_{0L} 为实际非病例数, E_{1L} 为期望病例数, E_{0L} 为期望非病例数, 自由度为组数减二, $10 - 2 = 8$ 。H 检验公式与 C 检验相同, C 分布与 H 分布近似卡方分布, 自由度为组数减二。

2. 参数的假设检验: 对模型中新加入参数的假设检验有三种。

①似然比检验: 通过对两个包含不同参数个数的 $\ln L$ 值, 对模型中的参数进行假设检验。求似然比统计量 G

$$\text{logit } P = \alpha + \sum_{k=1}^q \beta_k E_k + \sum_{i=1}^{p_1} r_i V_i + \sum_{k=1}^q \sum_{j=1}^{p_2} \delta_{kj} E_k W_j$$

诸暴露因素暴露条件 E^* 与 E^{**} 的比数比为

$$\text{OR}(E^*, E^{**}) = \exp \left[\sum_{k=1}^q (\beta_k^* - \beta_k^{**}) + (\beta_k + \sum_{j=1}^{p_2} \delta_{kj} W_j) \right] \quad (69)$$

当暴露因素只有一个, 即 $q=1$, E^* 与 E^{**} 的比数比为

$$\text{OR}(E^*, E^{**}) = \exp \left[(\beta^* - \beta^{**}) + (\beta + \sum_{j=1}^{p_2} \delta_{j1} W_j) \right] \quad (70)$$

若不存在效应修正变量, 即 $\delta=0$, 仅考虑单一暴露变量 E, 两组暴露条件 E^* 和 E^{**} 之差等于 1 时, 比数比为

$$\text{OR}(E^*, E^{**}) = \exp [(\beta)(E^* - E^{**})] = \exp(\beta) \quad (71)$$

$$G = 2(\ln t_f - \ln L_t) \quad (66)$$

上式中 t 为原包含在模型中的参数个数, f 为所加入的参数的个数, 统计量 G 服从自由度为 f 的 χ^2 分布。通过 χ^2 检验考察 f 个参数贡献有无显著意义。有显著性者纳入模型, 不显著者剔除出模型。

②Z 检验: 计算模型中各因素的偏回归系数 $\hat{\beta}_k$ 及其方差 $V(\hat{\beta}_k)$, 进而用公式 67 求标准化偏回归系数的估计值 $Z = \hat{\beta}_k / \sqrt{V(\hat{\beta}_k)}$, 在大样本中该值呈标准正态分布 (u 布), $H_0: \beta_k = 0$, 对 Z 值进行检验, 不显著则剔出模型, 显著则纳入模型。

③积分统计量 (score statistic): 又称记分检验或梯度检验。设对数似然函数的一阶偏导数矢量为 $S = S(\beta_0, \beta)$, 二阶偏导数矩阵的负值为信息矩阵 $I = I(\beta_0, \beta)$, 若检验假设 $H_0: \beta_1 = 0$, 用下式计算 S

$$S = [S(\beta_0, \beta)]^T [-I(\beta_0, \beta)]^{-1} [S(\beta_0, \beta)] \quad (68)$$

S 分布近似 χ^2 分布, 自由度亦为新引入的参数个数。这种方法计算较繁, 稳定性较差, 国内很少应用。

(六) 比数比 (odds ratio) 的计算: 设有 q 个暴露因素 E, P_1 个混杂因素 V, P_2 个效应修正变量 W (交互作用), Logistic 模型可表示为

二、Logistic 模型适用条件和在病例对照研究中的应用

(一) 适用条件: 第一, 因变量必须是两项分类 (0, 1 型) 的数据, 或必须限于 0~1 之间的数据。第二, 每个自变量 X 与因变量 P 之间呈单调上升或下降的 S 形曲线, 或者说自变量 X 与 Logit P 之间呈线性关系。自变量的效应呈相乘的统计关系。

(二) Logistic 模型在病例对照研究中的应用: Logistic 模型有两种, 即非条件 Logistic 模型与条件 Logistic 模型, 前者可用于非配比的病例对照研究, 后者用于配比的病例对照研究。在应用非条件 Logistic 模型时, 对于分层资料必须引入反映层次的变量。由于这两种模型的似然函数不同, 所以计算也不一样, 通常各有其计算机专用程序, 在电子计算机上运算。程序的使用方法可参考有关的使用说明。