

社会统计分析第十六讲

六月廿四日下午

昨天下午我们讲了净相关系数: $r_{xy \cdot z}$; $r_{xy \cdot zw}$; $r_{xy \cdot zwT}$.
这些净相关系数假定变量都是定距变量。它的作用很大, 可以控制一个变量, 也可以控制两个变量、三个变量等。

假如昨天讲的样本都是随机样本, 进行总体推论时就可以用F检定法, 即:

$$F = \frac{\text{估计总体之缩减误差}}{\text{估计总体之剩余误差}} = \frac{\text{净 } Y^2 / df_1}{(1 - \text{净 } Y^2) / df_2}$$

由于

$$\begin{cases} df_1 = 1 \\ df_2 = n - k - 2 \\ k = \text{控制变量数} \end{cases}$$

代入公式就是

$$F = \frac{\text{净 } Y^2}{1 - \text{净 } Y^2} (n - k - 2)$$

如果我们只控制一个变量 z , 即 $r_{xy \cdot z}$

$$F = \frac{r_{xy \cdot z}^2 (n - 3)}{1 - r_{xy \cdot z}^2} \quad \text{其中 } df_1 = 1, df_2 = n - 1 - 2 = n - 3$$

这是一级相关系数之检定。

假如我们现在控制两个变量 z, w , 即 $r_{xy \cdot zw}$, 因 $df_1 = 1$;
 $df_2 = n - 2 - 2$; $k = 2$

$$\text{所以 } F = \frac{r_{xy \cdot zw}^2 (n - 4)}{1 - r_{xy \cdot zw}^2}$$

3 — 1


如果我们控制三个变易 Z, W, T .

同理:
$$F = \frac{Y_{xy \cdot ZWT}^2 (n-5)}{1 - Y_{xy \cdot ZWT}^2}$$

以下控制多少变易可以同理类推。

现在给大家讲一个例子。

昨天讲过的表十一的资料是关于29个生产大队的耕人比、离城远近与工业发展水平的关系。假定这29个生产大队是从一个县里抽出的随机样本，三变易之关系如左所示：



其中 $Y_{xy \cdot Z} = -0.47$

$n = 29$

这说明控制 Z 后， X 与 Y 成反比关系。现在我们要问，如果按样本推论总体，在总体里控制 Z 后， X 与 Y 是否还有关系。

这种推论可表示为 H_1 : 总体 $Y_{xy \cdot Z} \neq 0$

虚无假设则表示为 H_0 : 总体 $Y_{xy \cdot Z} = 0$

怎样检验 H_0 呢？用 F 检验法。

因为这是控制一个变易，所以

$$F = \frac{Y_{xy \cdot Z}^2 (n-3)}{1 - Y_{xy \cdot Z}^2} = \frac{-0.47^2 (29-3)}{1 - (-0.47)^2} = 7.372$$

根据 $df_1 = 1, df_2 = 29-3 = 26$ 查 F 表, $F_{0.05} \geq 4.225$.


而因为 $F = 7.372 > 4.225$, 所以可以否定 H_0 , 接受 H_1 , 即控制 Z 后, X 与 Y 还有显著关系。

为什么要说显著关系呢？因为它的根据是显著水平，所表示的是 X 与 y 在总体里的关系，今后我说显著关系就是指 X 与 y 在总体内有关系（当然根据某显著水平而言）。

第十章 多因回归与複相关

第一节：什么是多因。

以前讲的是一个变量怎样受另一个变量影响，实际上任何一个变量是受很多变量影响的。



这就是多因的问题：

例如研究犯罪问题，失业可能是犯罪的原因，都市化、人口密度等都可能也是犯罪的原因。

又如研究青年人找对象为什么困难的原因，可能性别、城乡背景、教育水平、父母职业等各方面都有影响。

现在人们常关心理想子女数目，造成理想子女数目不一的原因可能是职业、年龄、性别、教育水平、城乡背景、民族背景、经济水平、夫妻关系、亲友的儿女数目以及住戶拥挤等。总之，从实际出发，引起事物变化往往是多因性的。

多因问题要从三方面理解：

- ①. 了解所有这些因素，同时对 y 的影响如何。
- ②. 比较之下，哪个因素对 y 的影响更重要。
- ③. 知道各因素（自变量）之值后，如何予测倚变量 y 之值。

第二节：複相关系数（multiple Correlation）

这里要讲的内容，假定全部变量都是定量变量。复相关系数是研究一组自变量同时影响 y 时，它们的共同效力怎么样。

复相关系数用 R 表示。

R 的统计值是 $0-1$ ，没有正负之分，因为研究一组定量变量只看效果大小，不能有正负抵消的问题。 R^2 有PRZ的解释，叫多元决定系数。

现在看复相关系数的公式。

如果研究 $\left. \begin{matrix} X_1 \\ X_2 \end{matrix} \right\} \rightarrow y$

那么复相关决定系数 $R^2_{y \cdot 12}$ 的公式如下：


$$R^2_{y \cdot 12} = Y^2_{y_1} + (Y^2_{y_2 \cdot 1})(1 - Y^2_{y_1})$$

复相关系数 $R_{y \cdot 12}$ 的公式如下：

$$R_{y \cdot 12} = \sqrt{R^2_{y \cdot 12}}$$

简单讲一下公式的来历。

如图。



y 表示不知 X_1 和 X_2 时予测 y 的全部误差， $(A+B)$ 是已知 X_1 予测 y 时消减的误差， $(B+C)$ 是已知 X_2 予测 y 时消减的误差。已知 X_1, X_2 予测 y 时，同时消减的误差 = $A+B+C$ ，亦即 $R^2_{y \cdot 12}$ ，公式中的 $Y^2_{y_1}$ 就是 $A+B$ 那一部分， $(Y^2_{y_2 \cdot 1})(1 - Y^2_{y_1})$ 就是剩余的部分 C 。加起来就表示 X_1 和 X_2 两个变量同时影响 y 时所消减之误差，所以它也有PRZ的解释。

但是这个公式计算起来麻烦，根据统计学家推论，可简化为如下：

$$R^2_{y.12} = \frac{r^2_{y1} + r^2_{y2} - 2r_{y1}r_{y2}r_{12}}{1 - r^2_{12}}$$

假如研究 y 同时受 x_1, x_2, x_3 的影响，即 $\begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} \rightarrow y$ 那么，

$$R^2_{y.123} = R^2_{y.12} + (r^2_{y3.12})(1 - R^2_{y.12})$$

複相关系数的公式便是：

$$R^2_{y.123} = \sqrt{R^2_{y.123}}$$

如果是，

$$\begin{pmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \end{pmatrix} \rightarrow y \quad \text{则其公式是：}$$

$$R^2_{y.1234} = R^2_{y.123} + (r^2_{y4.123})(1 - R^2_{y.123})$$

(注意：关于 R 之修正，参看第十九讲)

现举例如下，

假定仍用表十一的资料，

$$\begin{cases} x_1 = \text{离城市远近} \\ x_2 = \text{公社大队耕人比} \\ y = \text{大队工业化程度} \end{cases}$$

$$\begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \rightarrow y$$

$$\begin{cases} r_{y1} = -0.51 \\ r_{y2} = -0.64 \\ r_{y3} = +0.67 \end{cases} \quad \text{则 } R^2_{y.12} = \frac{r^2_{y1} + r^2_{y2} - 2r_{y1}r_{y2}r_{12}}{1 - r^2_{12}} \\ = \frac{(-0.51)^2 + (-0.64)^2 - 2(-0.51)(-0.64)(0.67)}{1 - (0.67)^2} \\ = \frac{0.23}{0.55} = 0.42$$

$$R_{y.12} = \sqrt{R^2_{y.12}} = \sqrt{0.42} = 0.65 \quad \text{即：} \quad \begin{array}{ccc} 0 & 0.65 & +1 \\ & \Delta & \end{array}$$

说明了 X_1, X_2 对 y 同时有影响。消减误差达 42%。
统计推论:

$$\text{设 } \begin{cases} H_1: R \neq 0 \text{ (总体)} \\ H_0: R = 0 \end{cases}$$

$$df_1 = k$$

$$df_2 = n - k - 1$$

k - 自变量的数目。则

$$F = \frac{R^2}{1-R^2} \left(\frac{n-k-1}{k} \right)$$

代入上述二十九个大队的例子, $n=29$ $k=2$ $R^2=0.42$ 则,

$$F = \frac{0.42}{1-0.42} \left(\frac{29-2-1}{2} \right) = 9.414$$

$$df_1 = k = 2$$

$$df_2 = n - k - 1 = 29 - 2 - 1 = 26$$

要求 $\alpha < 0.05$ 则 $F_{0.05} \geq 2.269$, 否定 H_0 , 说明了 X_1, X_2 对 y 都同时有影响 (在总体内)


第三节: 多元直线回归分析

上述模相关系数。

其模式是:

$$\begin{pmatrix} X_1 \\ X_2 \\ X_3 \\ X_4 \\ \vdots \end{pmatrix} \rightarrow y$$

现讲多元直线回归分析, 其模式则是:



多因直线回归分析的作用是：

一、估计 y 值；

二、比较各个 X 的效力。

以前讲过的简单直线回归分析，是研究一个 X 与一个 Y 的关系，而现在讲的多因直线回归分析，则是讲多个 X 与一个 Y 的关系。

还是让我们再从简单直线回归分析谈起。

$$X \rightarrow Y$$

$y' = bx + a$ ，这方程式内的 b ，其实是 b_{yx} ，表示 b 为 y 受 x 影响的 b 。亦即说， $b_{yx} \neq b_{xy}$ ，因 $x' = b_{xy}y + a$ 。故

$$b_{yx} = \frac{\Delta y'}{\Delta x}$$

b 的大小受测量单位影响，所谓测量单位，就是指测量以什么单位来计测。比如时间的测量单位，可以是年，可以是月，也可以是日。测量的单位不同， b 值的大小，也是不相同的。

比如：

教育年数 (x) $\rightarrow$ 理想子女数目 (y)

就是以年为测量单位，因此，如果测量单位改为月， b 的大小亦会随之改变。

因为 b 的大小视测量单位而定，故难于比较，例如：

$$\left. \begin{aligned} y' &= b_1 x_1 + a_1 \\ y' &= b_2 x_2 + a_2 \end{aligned} \right\} b_1 \text{ 与 } b_2 \text{ 之大小视于 } x_1 \text{ 与 } x_2 \text{ 之测量单位}$$

位，故 b 可用于预测，而不可用于比较。而为了比较 b ，则需使 b 标准化，亦即使每一变量之值变为标准值 (Standard Score)，就不受测量单位影响。

例如：

$$X \Rightarrow Z_x$$

$$y \Rightarrow Z_y$$

$$Z_x = \frac{x - \bar{x}}{S_x}$$

$$Z_y = \frac{y - \bar{y}}{S_y}$$

这样， x, y 就都变为标准值 Z

变量 x 的标准化就是以它自己的均值为 0 点，然后，每个变量值之距离则以它自己变量的标准差 (S) 为单位。 y 变量同理。

例如《表八》：

x	y	Z_x	Z_y
2	5	-1.09	+1.59
2	4	-1.09	+1.06
3	4	-0.55	+1.06
3	3	-0.55	+0.53
4	1	0.00	-0.53
4	1	0.00	-0.53
4	0	0.00	-1.06
6	0	+1.09	-1.06
8	0	+2.19	-1.06
$\bar{x} = 4$ $S_x = 1.85$	$\bar{y} = 2$ $S_y = 1.89$	$\bar{Z}_x = 0$ $S'_x = 1$	$\bar{Z}_y = 0$ $S'_y = 1$

怎样把 x 变成标准值呢？以表中第一名妇女所给的数据计算如下：

$$\begin{cases} Z_x = \frac{2 - 4}{1.82} = -1.09 \\ Z_y = \frac{5 - 2}{1.89} = 1.59 \end{cases}$$

由上可见，只要变为标准值，不管任何变量，其均值皆为0，其标准差皆为1。因此：

$$\begin{cases} y = bx + a \\ z'_y = \beta z_x, \end{cases} \quad \beta \text{ 是标准化回归系数} = \text{回归权重 (bataweight)}$$

$$\beta = \beta_{yx} = \frac{\Delta z'_y}{\Delta z_x}$$

$$= b_{yx} \left(\frac{s_x}{s_y} \right)$$

为何 $z'_y = \beta z_x$ 的后面没有 a ？

因为 $a = \bar{y} - b\bar{x}$


$$A = \bar{z}_y - \beta \bar{z}_x$$

$$\text{而 } \bar{z}_y = 0 \quad \bar{z}_x = 0$$


所以 $A = 0$

如下图所示：

图(-)





图(=)



由图(-)可见，图 $z'_y = \beta z_x$ 的后面没有截距 A ，故 $z'_y = \beta z_x$ 这条线通过0点。

由图(=)可见，图 $y = bx + a$ 的后面有截距 a ，故 $y = bx + a$ 这条线不一定通过0点。

现在讲两个变量同时影响 y 。



$$y' = b_1 X_1 + b_2 X_2 + a_{12} \quad \text{多元直线回归方程式}$$

$$Z'y = \beta_1 Z_1 + \beta_2 Z_2 \quad \text{标准化多元直线回归方程式}$$

三条线称为直角关系，表示三度空间，用一条直线穿过所有的点，这条直线根据最小平方法求出。所以根据 X_1, X_2 的数值来估计 y 值，其误差最小。

标准化直线回归方程式有比较效力的作用。

以上两个方程式有不同的作用。首先，让我们解释 b_1 和 b_2 这两个系数。

b_1 实际上应当写作 $b_{y1.2} = \frac{\Delta y'}{\Delta X_1}$ = 净回归系数。即在控制 X_2 以后， X_1 变化引起 y 变化的数值。

b_2 实际上应当写作 $b_{y2.1} = \frac{\Delta y'}{\Delta X_2}$ = 净回归系数。即在控制 X_1 以后， X_2 变化引起 y 变化的数值。

$$a_{12} = \text{截距} = \bar{y} - b_1(\bar{X}_1) - b_2(\bar{X}_2)$$

计算标准化回归系数同理：

$$\beta_1 = \beta_{y1.2} = \text{控制 } X_2 \text{ 以后的标准净回归系数} = \text{回归权重。}$$

$$\beta_2 = \beta_{y2.1} = \text{控制 } X_1 \text{ 以后的标准净回归系数} = \text{回归权重。}$$

怎样计算 $b_1, b_2, \beta_1, \beta_2$ 呢？根据统计学家推算，用最小

平方法，那么计算公式为：

$$\begin{cases} \beta_1 = \beta_{y_{1.2}} = \frac{r_{y_1} - r_{y_2} r_{12}}{1 - r_{12}^2} \\ \beta_2 = \beta_{y_{2.1}} = \frac{r_{y_2} - r_{y_1} r_{12}}{1 - r_{12}^2} \end{cases}$$

$$\begin{cases} b_1 = \beta_1 \left(\frac{s_y}{s_1} \right) \\ b_2 = \beta_2 \left(\frac{s_y}{s_2} \right) \end{cases}$$

$$a_{12} = \bar{y} - b_1(\bar{x}_1) - b_2(\bar{x}_2)$$

例：

(X_1) 离城远近 $\rightarrow$
 (X_2) 耕地与人口比率 $\rightarrow$ 工业化程度 (Y)

假如： $r_{y_1} = -0.51$

$$s_y = 3.61$$

$$r_{y_2} = -0.64$$

$$s_1 = 3.02$$

$$r_{12} = +0.67$$

$$s_2 = 0.21$$

$$R = 0.65$$

$$\bar{y} = 4.72$$

$$\bar{x}_1 = 5.74$$

$$\bar{x}_2 = 1.23$$

那么我们的离城远近和耕地比率哪一个因素对工业化影响更大一些？计算：

$$\beta_1 = \frac{(-0.51) - (-0.64)(0.67)}{1 - (0.67)^2} = 0.15$$

$$\beta_2 = \frac{(-0.64) - (-0.51)(0.67)}{1 - (0.67)^2} = -0.54$$

$$b_1 = (-0.15) \left(\frac{3.61}{3.02} \right) = -0.18$$

$$b_2 = (-0.54) \left(\frac{3.61}{0.21} \right) = -9.28$$

$$a_{12} = \bar{y} - b_1 \bar{X}_1 - b_2 \bar{X}_2 = 4.72 - (-0.18)(5.47) - (-9.28)(1.23) = 17.11$$

所以
$$\begin{cases} Y' = -0.18 X_1 - 9.28 X_2 + 17.11 \\ Z'y = -0.15 Z_1 - 0.54 Z_2 \end{cases}$$

可见，耕地与人口比率比离城远近对工业化的影响更大些，怎么预测呢？以表十一中第五个大队为例。该大队离城 7.8 公里，耕人比 1.23 亩/每人 $\begin{cases} X_1 = 7.8 \\ X_2 = 1.23 \end{cases}$

根据 X_1, X_2 估计 Y (工业化程度)。将以上数值代入公式：

$$Y' = -0.18(7.8) - 9.28(1.23) + 17.11 = 3.5。$$

根据计算，我们就可以回答这个大队有 3.5% 的人口是参加工业的。(实际上是 3.9%，相差不多)。

现在讲三个变量：



公式是：

$$\begin{cases} Y' = b_1 X_1 + b_2 X_2 + b_3 X_3 + a_{123} \\ Z'y = \beta_1 Z_1 + \beta_2 Z_2 + \beta_3 Z_3 \end{cases}$$

其中： $b_1 = b_{Y1.23} = \beta_1 \left(\frac{S_Y}{S_1} \right)$

$$b_2 = b_{Y2.13} = \beta_2 \left(\frac{S_Y}{S_2} \right)$$

$$b_3 = b_{Y3.12} = \beta_3 \left(\frac{S_Y}{S_3} \right)$$

$$a_{123} = \bar{y} - b_1 \bar{X}_1 - b_2 \bar{X}_2 - b_3 \bar{X}_3$$

从以上几个式子可以看出，只要求出 $\beta_1, \beta_2, \beta_3$ ，其它就容易计算了。

据统计学家推论：

$$\beta_1 + r_{12}\beta_2 + r_{13}\beta_3 = r_{y1} \dots\dots\dots ①$$

$$r_{12}\beta_1 + \beta_2 + r_{23}\beta_3 = r_{y2} \dots\dots\dots ②$$

$$r_{31}\beta_1 + r_{32}\beta_2 + \beta_3 = r_{y3} \dots\dots\dots ③$$

又因为 r 不计方向 ($X \leftrightarrow Y$)，故 $r_{32} = r_{23}$ 。

运用代数运算，可根据上面三个方程式解出三个未知数

$\beta_1, \beta_2, \beta_3$ 。

$$\text{设: } \begin{cases} r_{y1} = 0.6735 \\ r_{y2} = 0.5320 \\ r_{y3} = 0.3475 \end{cases} \quad \begin{cases} r_{12} = 0.1447 \\ r_{13} = 0.3521 \\ r_{23} = 0.0225 \end{cases}$$

代入方程式①、②、③，则：

$$\beta_1 + 0.1447\beta_2 + 0.3521\beta_3 = 0.6735$$

$$0.1447\beta_1 + \beta_2 + 0.0225\beta_3 = 0.5320$$

$$0.3521\beta_1 + 0.0225\beta_2 + \beta_3 = 0.3475$$

$$\text{解得: } \begin{cases} \beta_1 = 0.5593 \\ \beta_2 = 0.4479 \\ \beta_3 = 0.1405 \end{cases}$$

$$\text{又设: } \begin{cases} S_y = 2.9469 \\ S_1 = 2.6651 \\ S_2 = 2.1151 \\ S_3 = 2.2100 \end{cases} \quad \begin{cases} \bar{y} = 5.50 \\ \bar{x}_1 = 4.95 \\ \bar{x}_2 = 5.50 \\ \bar{x}_3 = 5.40 \end{cases}$$

把以上数字代入 b_1, b_2, b_3 公式及 a_{123} 公式：

$$b_1 = 0.5593 \left(\frac{2.9469}{2.6651} \right) = 0.6184$$

$$b_2 = 0.4479 \left(\frac{2.9469}{2.1151} \right) = 0.6240$$

控制 X_2, X_3 时, 结果 β_1 数值很小; 控制 X_1, X_3 时, β_2 数值也会很小了而控制 X_1, X_2 时, 由于不影响 X_3 之效力, β_3 二数值就会较大了。

这样, β_3 就显得很重要, 我们得出 X_3 的效力大于 X_1, X_2 就不一定准确了, 这就是统计累赘问题。

因此, 在运用回归权数比较 X_1, X_2, X_3 的效力时, X_1, X_2, X_3 之间的相关系数要差不多, $r_{12} \approx r_{13} \approx r_{23}$, 才能避免统计累赘。

当然, 如果我们只根据单回归系数(b)来推测 y' 的值, 就不必考虑这个问题了。

社会统计分析第十七讲

六月二十五日下午讲

$$y' = b_1 X_1 + b_2 X_2 + a_{12}$$

$$Z'_y = \beta_1 Z_1 + \beta_2 Z_2$$

上面两个公式是多因直线回归分析方程式。现在我们讨论推论到总体的情况。一般有两种做法:

$$\textcircled{1} \begin{cases} H_1: \text{在总体为 } b_1 \text{ 或 } b_2 \neq 0 \text{ 即 } \beta_1 \text{ 或 } \beta_2 \neq 0 \text{ 或 } R \neq 0 \\ H_0: \quad \quad \quad b_1 = b_2 = 0 \text{ 即 } \beta_1 = \beta_2 = 0 \text{ 或 } R = 0 \end{cases}$$

以上的虚无假设就是说两个自变量 X_1 和 X_2 同时与因变量 y 无关。问题是我们如何来鉴定这一虚无假设。此时用以前讲过的F检定法。

$$\text{即: } F = \frac{R^2}{1-R^2} \left(\frac{n-k-1}{k} \right), \text{ 而 } df_1 = k, df_2 = n-k-1$$

(其中 k 为自变量的数目)

$$\textcircled{2} \begin{cases} H_1: b_1 \neq 0 \\ H_0: b_1 = 0 \end{cases} \text{ 和 } \begin{cases} H_1: b_2 \neq 0 \\ H_0: b_2 = 0 \end{cases}$$

也就是说将自变量分离开来进行检查, 用F检验法先对 b_1 检查, 然后同理对 b_2 检查. 下面是对 b_1 的检查公式:

$$F = \frac{\gamma_{y(1.2)}^2}{1 - R^2_{y.12}} (n - k - 1)$$

$$df_1 = 1$$

$$df_2 = n - k - 1$$

这里注意:

$$\gamma_{y(1.2)} \neq \gamma_{y1.2}$$

因为 $\gamma_{y1.2}$ = 净相关系数,

而 $\gamma_{y(1.2)}$ = 局部相关系数 (Part Correlation)

根据统计推论, 局部相关系数的计算公式为:

$$\gamma_{y(1.2)}^2 = \frac{\gamma_{y1} - \gamma_{y2} \gamma_{12}}{\sqrt{1 - \gamma_{y2}^2}}$$

所以对 b_1 的检查首先应算出 $\gamma_{y(1.2)}$ 的值, 然后代入即可求得F值. 同理对 b_2 的检查公式:

$$F = \frac{\gamma_{y(2.1)}^2 \cdot (n - k - 1)}{1 - R^2_{y.12}}$$

$$\text{其中 } \gamma_{y(2.1)}^2 = \frac{\gamma_{y2} - \gamma_{y1} \gamma_{12}}{\sqrt{1 - \gamma_{y1}^2}}, \quad df_1 = 1$$

$$df_2 = n - k - 1$$

第四节 逐步回归分析之程序

上一节谈到, 在多元回归方程式 (如 $y' = b_1x_1 + b_2x_2 + b_3x_3 + a_{123}$) 中, 各个自变量 (如 x_1, x_2, x_3) 同时影响倚变量 y .

逐步回归分析则不同，它是各个自变量依先后次序进入回归方程式的。如：第一步： $y' = b_2 X_2 + a_2$

第二步： $y' = b_2 X_2 + b_1 X_1 + a_{21}$

第三步： $y' = b_2 X_2 + b_1 X_1 + b_3 X_3 + a_{213}$

这样就能依次逐步分析一个两个乃至三个变量对 y 的不同影响，即每放入一个变量就能估计一次消减误差之增长。见下表。

次序	方程式	PRE	增加之PRE	表示(阴影部分)
第一步	$y' = b_2 X_2 + a_2$	Y_{y2}^2	Y_{y2}^2	
第二步	$y' = b_2 X_2 + b_1 X_1 + a_{21}$	$R_{y.12}^2$	$R_{y.12}^2 - Y_{y2}^2$	
第三步	$y' = b_2 X_2 + b_1 X_1 + b_3 X_3 + a_{213}$	$R_{y.123}^2$	$R_{y.123}^2 - R_{y.12}^2$	

为什么要研究增加之PRE呢？这实为了挑选比较有效力的自变量。譬如当放入第二个变量时，PRE增加不少，说明放入之变量效力很高，而再放入第三个变量时，PRE的增加量甚微，说明此变量对 y 影响很小，可以不必考虑。这在自变量过多时帮助取舍自变量，以简化资料。

这样产生的一个问题，哪一个自变量首先放入呢？即先后次序如何确定？有两种方法：第一种是根据研究理论来确定先后次序，社会学家对影响畸变变量之诸因素加以分析，并认为在理论上较重要的自变量首先放入方程式。例如：

y = 个人现代化

X_1 = 入息

X_2 = 教育

X_3 = 智能