

第十三讲 约束最小二乘和 F 检验

2022.11.25

给定 \mathbf{x}_1 检验 \mathbf{x}_2 的效应是否显著

$$F = \frac{n-p}{q} \times \frac{R_{2\cdot 1}^2}{1-R_{2\cdot 1}^2},$$

$R_{2\cdot 1}^2$ = 控制 \mathbf{x}_1 条件下 y 与 \mathbf{x}_2 的部分决定系数

约束最小二乘

在有些问题，主要是假设检验问题中，回归系数满足某些线性约束,比如 $\beta_1 = 0, \beta_1 = \beta_2, \beta_2 = (\beta_1 + \beta_3)/2$ 等，皆可表示为 $A\boldsymbol{\beta} = \mathbf{c}_0$, \mathbf{c}_0 已知,的形式。

约束最小二乘问题

假设线性模型 $\mathbf{y} = X_{n \times p} \boldsymbol{\beta} + \boldsymbol{\varepsilon}$, $\boldsymbol{\varepsilon} \sim (0, \sigma^2 I_n)$, 假设 X 列满秩, 设 $A_{q \times p}$ 为行满秩常数矩阵, \mathbf{c}_0 为已知的 $q \times 1$ 常数向量, (线性)约束最小二乘问题

$$\min_{\boldsymbol{\beta} \in R^p} \|\mathbf{y} - X\boldsymbol{\beta}\|^2 \quad s.t. \quad A\boldsymbol{\beta} = \mathbf{c}_0 \quad (*)$$

命题1. 上述约束最小二乘问题的最优解(约束最小二乘估计)为

$$\tilde{\boldsymbol{\beta}} = \hat{\boldsymbol{\beta}} - (X^T X)^{-1} A^T (A (X^T X)^{-1} A^T)^{-1} (A \hat{\boldsymbol{\beta}} - \mathbf{c}_0)$$

其中 $\hat{\boldsymbol{\beta}} = (X^T X)^{-1} X^T \mathbf{y}$ 为无约束条件下的LS估计。

证明: 对于约束 $A\boldsymbol{\beta} = \mathbf{c}_0$, 应用拉格朗日乘子法, 令

$$f(\boldsymbol{\beta}, \boldsymbol{\lambda}) = \|\mathbf{y} - X\boldsymbol{\beta}\|^2 + 2\boldsymbol{\lambda}^\top (A\boldsymbol{\beta} - \mathbf{c}_0)$$

对 $\boldsymbol{\beta}$ 求偏导并令之为 0 得

$$X^\top X\boldsymbol{\beta} - X^\top \mathbf{y} + A^\top \boldsymbol{\lambda} = 0$$

$$\Rightarrow \tilde{\boldsymbol{\beta}} = (X^\top X)^{-1} X^\top \mathbf{y} - (X^\top X)^{-1} A^\top \boldsymbol{\lambda} = \hat{\boldsymbol{\beta}} - (X^\top X)^{-1} A^\top \boldsymbol{\lambda}$$

代入 $A\tilde{\boldsymbol{\beta}} = \mathbf{c}_0$ 得 $A\hat{\boldsymbol{\beta}} - A(X^\top X)^{-1} A^\top \boldsymbol{\lambda} = \mathbf{c}_0$, 即 $A(X^\top X)^{-1} A^\top \boldsymbol{\lambda} = A\hat{\boldsymbol{\beta}} - \mathbf{c}_0$,

所以 $\boldsymbol{\lambda} = (A(X^\top X)^{-1} A^\top)^{-1} (A\hat{\boldsymbol{\beta}} - \mathbf{c}_0)$,

$$\Rightarrow \tilde{\boldsymbol{\beta}} = \hat{\boldsymbol{\beta}} - (X^\top X)^{-1} A^\top (A(X^\top X)^{-1} A^\top)^{-1} (A\hat{\boldsymbol{\beta}} - \mathbf{c}_0). \quad \square$$

引理1. 约束 $A_{q \times p} \boldsymbol{\beta} = \mathbf{0}$ 成立时, X 张成的空间(下面称自变量空间)

定义为 $V_0 = \{X\boldsymbol{\beta} : A\boldsymbol{\beta} = \mathbf{0}, \boldsymbol{\beta} \in R^p\} \subset V = C(X)$, 则

$$V_0 = C(X(X^T X)^{-1} A^T)^\perp \cap C(X)$$

进而 V_0 空间的投影阵为 $P_{V_0} = P_X - P_{X(X^T X)^{-1} A^T}$.

证明: 记 $\boldsymbol{\mu} = X\boldsymbol{\beta} \Rightarrow \boldsymbol{\beta} = (X^T X)^{-1} X^T \boldsymbol{\mu}$,

若 $\boldsymbol{\mu} \in V_0$, $\mathbf{0} = A\boldsymbol{\beta} = A(X^T X)^{-1} X^T \boldsymbol{\mu} \Rightarrow \boldsymbol{\mu} \in C(X(X^T X)^{-1} A^T)^\perp$, 但 $\boldsymbol{\mu} \in C(X)$,

所以 $\boldsymbol{\mu} \in C(X) \cap C(X(X^T X)^{-1} A^T)^\perp$, 所以 $V_0 \subset C(X) \cap C(X(X^T X)^{-1} A^T)^\perp$ 。

反之也对, 所以 $V_0 = C(X) \cap C(X(X^T X)^{-1} A^T)^\perp$,

即 $C(X(X^T X)^{-1} A^T) \oplus V_0 = C(X)$,

所以 $P_X = P_{X(X^T X)^{-1} A^T} + P_{V_0}$.

不妨假设 $\mathbf{c}_0 = \mathbf{0}$, 这是因为 $A\boldsymbol{\beta} = \mathbf{c}_0 \Leftrightarrow$

$A[\boldsymbol{\beta} - A^\top(AA^\top)^{-1}\mathbf{c}_0] = \mathbf{0}$, 令 $\underline{\boldsymbol{\beta}^* = \boldsymbol{\beta} - A^\top(AA^\top)^{-1}\mathbf{c}_0}$, 此时模型

$$\mathbf{y} = X\boldsymbol{\beta} + \boldsymbol{\varepsilon} = X(\boldsymbol{\beta}^* + A^\top(AA^\top)^{-1}\mathbf{c}_0) + \boldsymbol{\varepsilon} = X\boldsymbol{\beta}^* + XA^\top(AA^\top)^{-1}\mathbf{c}_0 + \boldsymbol{\varepsilon}$$

即 $\mathbf{y}^* \triangleq \mathbf{y} - XA^\top(AA^\top)^{-1}\mathbf{c}_0 = X\boldsymbol{\beta}^* + \boldsymbol{\varepsilon}$.

在原模型中约束 $A\boldsymbol{\beta} = \mathbf{c}_0 \Leftrightarrow$ 在模型 $\mathbf{y}^* = X\boldsymbol{\beta}^* + \boldsymbol{\varepsilon}$ 约束 $A\boldsymbol{\beta}^* = \mathbf{0}$.

命题1的几何证明:

\mathbf{y} 在 V_0 上的投影 $\hat{\mathbf{y}}_0 = P_{V_0}\mathbf{y}$ 使得约束最小二乘(*)达到最小, 由引理1,

$$\hat{\mathbf{y}}_0 = P_{V_0}\mathbf{y} = P_V\mathbf{y} - P_{X(X^\top X)^{-1}A^\top}\mathbf{y} = X\hat{\boldsymbol{\beta}} - X(X^\top X)^{-1}A^\top(A(X^\top X)^{-1}A^\top)^{-1}A\hat{\boldsymbol{\beta}}$$

$$= X\left[\hat{\boldsymbol{\beta}} - (X^\top X)^{-1}A^\top(A(X^\top X)^{-1}A^\top)^{-1}A\hat{\boldsymbol{\beta}}\right]$$

$$\Rightarrow \tilde{\boldsymbol{\beta}} = \hat{\boldsymbol{\beta}} - (X^\top X)^{-1}A^\top(A(X^\top X)^{-1}A^\top)^{-1}A\hat{\boldsymbol{\beta}}.$$

注：在具体的约束LS问题中，我们通常将线性约束代入模型得到简化的无约束模型，再应用LS。例如，假设模型

$$\mathbf{y} = \mathbf{1}\beta_0 + \mathbf{x}_1\beta_1 + \cdots + \mathbf{x}_{p-1}\beta_{p-1} + \boldsymbol{\varepsilon}$$

有约束 $\beta_1 = \cdots = \beta_{p-1}$ ，代入模型得 $\mathbf{y} = \mathbf{1}\beta_0 + (\mathbf{x}_1 + \cdots + \mathbf{x}_{p-1})\beta_1 + \boldsymbol{\varepsilon}$ ，这是简单线性模型，易得 β_1 的LS估计。

例1(中文课本例3.3.1, p43), 测量三角形的三个内角 $\theta_1, \theta_2, \theta_3$ 得测量值 y_1, y_2, y_3 ，试求 $\theta_1, \theta_2, \theta_3$ 的最小二乘估计。

直观解法：在 $\theta_1 + \theta_2 + \theta_3 = \pi$ 约束下， y_2, y_3 对于估计 θ_1 也有帮助，我们可利用三次测量之和与 π 的差估算每一次测量的系统误差： $\hat{\delta} = (y_1 + y_2 + y_3 - \pi)/3 = \bar{y} - \pi/3$ ，则 θ_i 的估计应为 $\hat{\theta}_i = y_i - \hat{\delta} = y_i - (y_1 + y_2 + y_3 - \pi)/3$ 。

我们在上述直观描述中实际上假设了线性模型

$$y_i = \delta + \theta_i + \varepsilon_i, \quad \varepsilon_i \sim (0, \sigma^2), i = 1, 2, 3, \quad \theta_1 + \theta_2 + \theta_3 = \pi$$

其中 δ 代表系统误差，将约束条件 $\theta_3 = \pi - \theta_1 - \theta_2$ 代入模型：

$$\begin{cases} y_1 = \delta + \theta_1 + \varepsilon_1 \\ y_2 = \delta + \theta_2 + \varepsilon_2 \\ y_3 = \delta + (\pi - \theta_1 - \theta_2) + \varepsilon_3 \end{cases} \Rightarrow \hat{\delta} = \bar{y} - \pi/3, \quad \hat{\theta}_i = y_i - \hat{\delta}$$

一般线性假设

科学是一种系统性的知识体系，它积累并组织可检验的有于万物万物的解释或理论。科学强调理论的可证伪性。科学不是寻求绝对的真理，而是在现有基础上，摸索式地不断接近真理。假设检验是对科学理论假设进行判断的工具。

一般线性假设

假设正态线性回归模型： $\mathbf{y}_{n \times 1} = X_{n \times p} \boldsymbol{\beta}_{p \times 1} + \boldsymbol{\varepsilon}_{n \times 1}$, $\boldsymbol{\varepsilon} \sim N_n(0, \sigma^2 I_n)$

$H_0: A\boldsymbol{\beta} = \mathbf{c}_0$ 称为一般线性假设，其中 A, \mathbf{c}_0 已知， A 行满秩。

有关 $\boldsymbol{\beta} = (\beta_0, \beta_1, \dots, \beta_{p-1})^\top$ 的检验问题一般都可写成上述线性假设的形式，如 $p = 4$ 时

$$H_0: \beta_1 = 0 \Leftrightarrow H_0: \mathbf{a}^\top \boldsymbol{\beta} = 0, \mathbf{a} = (0, 1, 0, 0)^\top$$

$$H_0: \beta_1 = \beta_2 = 0 \Leftrightarrow H_0: A\boldsymbol{\beta} = 0, A = \begin{pmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{pmatrix}$$

但 A 的选取方式不唯一。上述第二个例子中也可取 $A = \begin{pmatrix} 0 & 1 & 0 & 0 \\ 0 & -1 & 1 & 0 \end{pmatrix}$

一般的Wald检验

Wald检验是已知构造直观的方法。非正态总体假设下，其原假设下的渐近分布为卡方分布（我们不证明该结论，但当总体为正态分布时，我们可以求出精确分布）。

单参数
情形

$H_0: \theta = \theta_0$ (θ_0 已知), $\hat{\theta}$ 为 θ 的极大似然估计或其它估计, Wald检验统计量

$$Z = (\hat{\theta} - \theta_0) / \sqrt{\widehat{\text{var}}(\hat{\theta})} \text{ 或 } W = Z^2 = (\hat{\theta} - \theta_0)^2 / \widehat{\text{var}}(\hat{\theta})$$

H_0 成立时, 近似地 (n 足够大时), $Z \sim N(0,1)$ 或 $W = Z^2 \sim \chi_1^2$ 。

多参数
情形

$H_0: \varphi(\boldsymbol{\theta}) = \mathbf{c}_0$ (\mathbf{c}_0 : 已知的 $q \times 1$ 向量), Wald统计量

$$W = (\varphi(\hat{\boldsymbol{\theta}}) - \mathbf{c}_0)^\top \hat{\Sigma}^{-1} (\varphi(\hat{\boldsymbol{\theta}}) - \mathbf{c}_0)$$

其中 $\hat{\boldsymbol{\theta}}$ 为 $\boldsymbol{\theta}$ 的极大似然估计或其它估计, $\Sigma = \text{var}(\varphi(\boldsymbol{\theta}))$, $\hat{\Sigma} = \widehat{\text{var}}(\varphi(\hat{\boldsymbol{\theta}}))$ 为 Σ 的估计。 H_0 成立时, 近似地 (n 足够大时),

$$W \sim \chi_q^2, n \rightarrow \infty$$

$$\hat{\Sigma}^{-1/2} (\varphi(\hat{\boldsymbol{\theta}}) - \mathbf{c}_0) \overset{\text{近似}}{\sim} N(\mathbf{0}, I_q)$$

线性模型的Wald检验和F检验

Wald 检验

模型 $\mathbf{y} = X\boldsymbol{\beta} + \boldsymbol{\varepsilon}$, $\boldsymbol{\varepsilon} \sim (0, \sigma^2 I_n)$, $H_0: A_{q \times p} \boldsymbol{\beta} = \mathbf{c}_0$ (已知), A 行满秩常数矩阵。

按照一般的Wald检验构建方式, H_0 的Wald检验定义为:

$$W = (A\hat{\boldsymbol{\beta}} - \mathbf{c}_0)^\top \left(A(X^\top X)^{-1} A^\top \right)^{-1} (A\hat{\boldsymbol{\beta}} - \mathbf{c}_0) / \hat{\sigma}^2 \stackrel{H_0, \text{近似}}{\sim} \chi_q^2$$

注意其中 $A(X^\top X)^{-1} A^\top = \text{var}(A\hat{\boldsymbol{\beta}} | X)$.

如果假设误差服从正态分布: $\boldsymbol{\varepsilon} \sim N(0, \sigma^2 I_n)$, 若定义 $F = W / q$,

则后面的命题2表明 $F \stackrel{H_0}{\sim} F_{q, n-p}$ (所以 $W \stackrel{H_0}{\sim} qF_{q, n-p}$)。

F检验

模型 $\mathbf{y} = X\boldsymbol{\beta} + \boldsymbol{\varepsilon}$, 假设误差服从正态分布 $\boldsymbol{\varepsilon} \sim N(0, \sigma^2 I_n)$,

原假设 $H_0: A_{q \times p} \boldsymbol{\beta} = \mathbf{c}_0$ (\mathbf{c}_0 已知, A 已知的行满秩矩阵) 的 F 检验定义为:

$$F = W / q = (A\hat{\boldsymbol{\beta}} - \mathbf{c}_0)^\top \left(A(X^\top X)^{-1} A^\top \right)^{-1} (A\hat{\boldsymbol{\beta}} - \mathbf{c}_0) / (q\hat{\sigma}^2).$$

为了证明原假设下 $F \sim F_{q, n-p}$, 需要引理2:

引理2. 假设 $\mathbf{x} \sim N(0, I_p)$, 即 \mathbf{x} 的各个分量 *iid* $\sim N(0,1)$, 假设 B 是投影矩阵, 则

(1) $\mathbf{x}^\top B \mathbf{x} = \|B \mathbf{x}\|^2 \sim \chi_r^2, r = \text{rank}(B)$

(2) 若 $AB = 0$, 则 $A \mathbf{x}$ 与 $B \mathbf{x}$ 独立, 特别地, $A \mathbf{x}$ 与 $\mathbf{x}^\top B \mathbf{x}$ 独立。

证明: 假设 B 的谱分解为 $B = O \begin{pmatrix} I_r & 0 \\ 0 & 0 \end{pmatrix} O^\top$, 令 $\mathbf{y} = O^\top \mathbf{x} = \begin{pmatrix} \mathbf{y}_1 \\ \mathbf{y}_2 \end{pmatrix} \sim N(0, I_p)$,

$$(1) \mathbf{x}^\top B \mathbf{x} = \mathbf{x}^\top O \begin{pmatrix} I_r & 0 \\ 0 & 0 \end{pmatrix} O^\top \mathbf{x} = (\mathbf{y}_1^\top, \mathbf{y}_2^\top) \begin{pmatrix} I_r & 0 \\ 0 & 0 \end{pmatrix} \begin{pmatrix} \mathbf{y}_1 \\ \mathbf{y}_2 \end{pmatrix} = \mathbf{y}_1^\top \mathbf{y}_1 \sim \chi_r^2.$$

$$(2) B \mathbf{x} = O \begin{pmatrix} I_r & 0 \\ 0 & 0 \end{pmatrix} O^\top \mathbf{x} = O \begin{pmatrix} \mathbf{y}_1 \\ 0 \end{pmatrix} = O_1 \mathbf{y}_1, \quad O_1 \text{ 为 } O = (O_1, O_2) \text{ 的前 } r \text{ 列.}$$

$$A \mathbf{x} = A O \mathbf{y} = (C, D) \begin{pmatrix} \mathbf{y}_1 \\ \mathbf{y}_2 \end{pmatrix}, \text{ 其中划分 } A O = (C, D)$$

$$\text{由 } AB = 0 \Rightarrow A O \begin{pmatrix} I_r & 0 \\ 0 & 0 \end{pmatrix} O^\top = 0 \Rightarrow (C, D) \begin{pmatrix} I_r & 0 \\ 0 & 0 \end{pmatrix} = 0 \Rightarrow C = 0,$$

所以 $A \mathbf{x} = D \mathbf{y}_2$, 所以 $A \mathbf{x}$ 与 $B \mathbf{x}$ 独立。

推论. 假设 P 是一个 $n \times n$ 投影矩阵, $r = \text{rank}(P) = \text{trace}(P)$,
若随机向量 $\mathbf{x} \sim N_n(0, I_n)$, 则


$$(0) \|\mathbf{x}\|^2 \sim \chi_n^2$$

$$(1) \|P\mathbf{x}\|^2 \sim \chi_r^2$$

$$(2) \|(I_n - P)\mathbf{x}\|^2 \sim \chi_{n-r}^2, \text{ 且与 } \|P\mathbf{x}\|^2 \text{ 独立}$$

$$(3) \frac{\|P\mathbf{x}\|^2/r}{\|(I_n - P)\mathbf{x}\|^2/(n-r)} \sim F_{r, n-r}$$

$$\frac{\|P\mathbf{x}\|^2}{\|\mathbf{x}\|^2} \sim \text{Beta}\left(\frac{r}{2}, \frac{n-r}{2}\right)$$




$$\begin{aligned} \|\mathbf{x}\|^2 &= \|P_V \mathbf{x}\|^2 + \|(I_n - P_V)\mathbf{x}\|^2 \\ \chi_n^2 &= \chi_{\dim(V)}^2 + \chi_{n-\dim(V)}^2 \end{aligned}$$

如P5所说，我们不妨仅考虑 $\mathbf{c}_0 = \mathbf{0}$ 的情形

命题2. 线性模型 $\mathbf{y} = X\boldsymbol{\beta} + \boldsymbol{\varepsilon}, \boldsymbol{\varepsilon} \sim N(0, \sigma^2 I_n)$, $H_0: A\boldsymbol{\beta} = \mathbf{0}$, 其中 $A_{q \times p}$ 行满秩已知。记 $V = C(X), V_0 = \{X\boldsymbol{\beta} : A\boldsymbol{\beta} = \mathbf{0}\}, \hat{\mathbf{y}} = P_V \mathbf{y}, \hat{\mathbf{y}}_0 = P_{V_0} \mathbf{y}$, 定义

$$F = \frac{(A\hat{\boldsymbol{\beta}})^\top (A(X^\top X)^{-1} A^\top)^{-1} (A\hat{\boldsymbol{\beta}})}{q\hat{\sigma}^2}, \text{ 则}$$

$$F = \frac{n-p}{q} \times \frac{\|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2}{\|\mathbf{y} - \hat{\mathbf{y}}\|^2} \stackrel{H_0}{\sim} F_{q, n-p}$$



$$\|\mathbf{y} - \hat{\mathbf{y}}_0\|^2 = \|\mathbf{y} - \hat{\mathbf{y}}\|^2 + \|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2$$

$$\|\mathbf{y} - \hat{\mathbf{y}}\|^2 = \|(I - P_V)\boldsymbol{\varepsilon}\|^2 \sim \sigma^2 \chi_{n-\text{di}(V)}^2$$

$$\|\mathbf{y} - \hat{\mathbf{y}}_0\|^2 = \|(I - P_{V_0})\boldsymbol{\varepsilon}\|^2 \sim \sigma^2 \chi_{n-\text{dim}(V_0)}^2$$

$$\|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2 = \|(P_V - P_{V_0})\boldsymbol{\varepsilon}\|^2 \sim \sigma^2 \chi_{\text{dim}(V) - \text{dim}(V_0)}^2$$

命题2的证明: (1) 我们首先证明 F 统计量的投影表达:

零假设成立时, β 满足约束 $A\beta = \mathbf{0}$,由命题1, 此时约束最小二乘估计

$$\tilde{\beta} = \hat{\beta} - (X^T X)^{-1} A^T (A(X^T X)^{-1} A^T)^{-1} A \hat{\beta},$$

拟合值向量: $\hat{y}_0 = X\tilde{\beta} = \hat{y} - X(X^T X)^{-1} A^T (A(X^T X)^{-1} A^T)^{-1} A \hat{\beta}$

$$\Rightarrow \|\hat{y} - \hat{y}_0\|^2 = \hat{\beta}^T A^T (A(X^T X)^{-1} A^T)^{-1} A \hat{\beta}$$

$$\Rightarrow F = \frac{\hat{\beta}^T A^T (A(X^T X)^{-1} A^T)^{-1} A \hat{\beta}}{q \hat{\sigma}^2} = \frac{n-p}{q} \times \frac{\|\hat{y} - \hat{y}_0\|^2}{\|\mathbf{y} - \hat{y}\|^2}.$$

H_0 成立时, $P_{X(X^T X)^{-1} A^T} X\beta = (\dots) A\beta = \mathbf{0}$, 所以

$$\hat{y} - \hat{y}_0 = P_{X(X^T X)^{-1} A^T} \mathbf{y} = P_{X(X^T X)^{-1} A^T} (X\beta + \varepsilon) = P_{X(X^T X)^{-1} A^T} \varepsilon$$

由引理4, $a = \|\hat{y} - \hat{y}_0\|^2 \sim \sigma^2 \chi_q^2$.

另一方面 $\mathbf{y} - \hat{y} = (I - P_V)(X\beta + \varepsilon) = (I - P_V)\varepsilon \Rightarrow b = \|\mathbf{y} - \hat{y}\|^2 \sim \sigma^2 \chi_{n-p}^2$

因为 $(I - P_V)P_{X(X^T X)^{-1} A^T} = \mathbf{0}$, a, b 独立, 所以 H_0 下 $F = \frac{a/q}{b/(n-p)} \sim F_{q, n-p}$.

命题3. (1) 记 RSS_0 , RSS 分别为原假设下和全模型下的残差平方和, 则

$$F = \frac{n-p}{q} \times \frac{(RSS_0 - RSS)}{RSS}$$

(2) 若 $A_{q \times p}$ 第一列为 $\mathbf{0}_{q \times 1}$, R_0^2 , R^2 分别为原假设下和全模型下的决定系数, 则

$$F = \frac{n-p}{q} \times \frac{R^2 - R_0^2}{1 - R^2}.$$

证明:(1) 因为 $\|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2 = \|\mathbf{y} - \hat{\mathbf{y}}_0\|^2 - \|\mathbf{y} - \hat{\mathbf{y}}\|^2 = RSS_0 - RSS \Rightarrow F = \frac{(RSS_0 - RSS)/q}{RSS/(n-p)}$

(2) 记 $A = (\mathbf{0}, B)$, 则 $A\boldsymbol{\beta} = (\mathbf{0}, B)\begin{pmatrix} \beta_0 \\ \mathbf{b} \end{pmatrix} = B\mathbf{b}$ (从而约束 $A\boldsymbol{\beta} = \mathbf{0}$ 对 β_0 没有约束),

而 $X\boldsymbol{\beta} = (\mathbf{1}, Z)\begin{pmatrix} \beta_0 \\ \mathbf{b} \end{pmatrix} = \mathbf{1}\beta_0 + Z\mathbf{b}$, 所以

$$V_0 = \{X\boldsymbol{\beta} : A\boldsymbol{\beta} = \mathbf{0}, \boldsymbol{\beta} \in R^p\} = \{\mathbf{1}\beta_0 + Z\mathbf{b} : B\mathbf{b} = \mathbf{0}, \mathbf{b} \in R^{p-1}\},$$

所以 $\mathbf{1} \in V_0$ (从而 $\mathbf{1} \perp \hat{\mathbf{y}} - \hat{\mathbf{y}}_0$, $\mathbf{1}^T \hat{\mathbf{y}}_0 = \mathbf{1}^T \hat{\mathbf{y}} = \mathbf{1}^T \mathbf{y} = n\bar{y}$)

$$\text{因为 } R^2 = \frac{\|\hat{\mathbf{y}} - \mathbf{1}\bar{y}\|^2}{\|\mathbf{y} - \mathbf{1}\bar{y}\|^2}, R_0^2 = \frac{\|\hat{\mathbf{y}}_0 - \mathbf{1}\bar{y}\|^2}{\|\mathbf{y} - \mathbf{1}\bar{y}\|^2}$$

$$\Rightarrow R^2 - R_0^2 = \frac{\|\hat{\mathbf{y}} - \mathbf{1}\bar{y}\|^2 - \|\hat{\mathbf{y}}_0 - \mathbf{1}\bar{y}\|^2}{\|\mathbf{y} - \mathbf{1}\bar{y}\|^2} = \frac{\|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2}{\|\mathbf{y} - \mathbf{1}\bar{y}\|^2}$$

$$\text{而 } 1 - R^2 = 1 - \frac{\|\hat{\mathbf{y}} - \mathbf{1}\bar{y}\|^2}{\|\mathbf{y} - \mathbf{1}\bar{y}\|^2} = \frac{\|\mathbf{y} - \hat{\mathbf{y}}\|^2}{\|\mathbf{y} - \mathbf{1}\bar{y}\|^2}, \Rightarrow \frac{\|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2}{\|\mathbf{y} - \hat{\mathbf{y}}\|^2} = \frac{R^2 - R_0^2}{1 - R^2}$$

$$\Rightarrow F = \frac{n-p}{q} \times \frac{R^2 - R_0^2}{1 - R^2}. \text{ 证毕。}$$

注：事实上，“ A 的第一列为 $\mathbf{0}$ ” \Leftrightarrow 约束 $A\boldsymbol{\beta} = \mathbf{0}$ 中不含截距项 $\beta_0 \Leftrightarrow \mathbf{1} \in V_0$ 。

这是因为由引理1我们知 $V_0 = C(X(X^\top X)^{-1}A^\top)^\perp \cap C(X)$,

$$\mathbf{1} \in V_0 \Leftrightarrow \mathbf{1} \perp C(X(X^\top X)^{-1}A^\top) \Leftrightarrow A(X^\top X)^{-1}X^\top \mathbf{1} = A \begin{pmatrix} 1/n \\ 0 \end{pmatrix} = \mathbf{0} \Leftrightarrow A \text{ 的第一列为 } \mathbf{0}.$$

参见第12讲P18的分块求逆公式

$$(X^\top X)^{-1} = \begin{pmatrix} a & -\bar{\mathbf{x}}^\top A^{-1} \\ -A^{-1}\bar{\mathbf{x}} & A^{-1} \end{pmatrix}, \text{ 其中 } A = (n-1)S_{\mathbf{xx}}, \quad a = 1/n + \bar{\mathbf{x}}^\top A^{-1}\bar{\mathbf{x}}$$

注解：在实际应用中，一般线性假设中的 A 矩阵，自变量空间 V_0 和 F 检验并不一定需要套用命题1中的公式，而是通过具体问题容易得到，例如：

$$(1) \mathbf{y} = X\boldsymbol{\beta} + \boldsymbol{\varepsilon} = X_1\boldsymbol{\beta}_1 + X_2\boldsymbol{\beta}_2 + \boldsymbol{\varepsilon}, \text{ 其中 } X = (X_1, X_2), \boldsymbol{\beta} = \begin{pmatrix} \boldsymbol{\beta}_1 \\ \boldsymbol{\beta}_2 \end{pmatrix}, H_0 : \boldsymbol{\beta}_2 = \mathbf{0}$$

H_0 成立时 $X\boldsymbol{\beta} = X_1\boldsymbol{\beta}_1$, 所以 $V_0 = L(X_1)$.

$$(2) \text{ 模型 } \mathbf{y} = X\boldsymbol{\beta} + \boldsymbol{\varepsilon} = \mathbf{1}\beta_0 + \mathbf{x}_1\beta_1 + \dots + \mathbf{x}_{p-1}\beta_{p-1} + \boldsymbol{\varepsilon}, H_0 : \beta_1 = \dots = \beta_{p-1}$$

$$H_0 \text{ 成立时 } X\boldsymbol{\beta} = \mathbf{1}\beta_0 + \mathbf{x}_1\beta_1 + \dots + \mathbf{x}_{p-1}\beta_{p-1} = \mathbf{1}\beta_0 + (\mathbf{x}_1 + \dots + \mathbf{x}_{p-1})\beta_1,$$

所以 $V_0 = L(\mathbf{1}, \mathbf{x}_1 + \dots + \mathbf{x}_{p-1})$.

Recap: F 检验的构造及零分布

$H_0: \theta = \theta_0$ 的Wald 检验 $W = (\hat{\theta} - \theta_0)^T [\text{var}(\hat{\theta})]^{-1} (\hat{\theta} - \theta_0)$


$\mathbf{y} = X\boldsymbol{\beta} + \boldsymbol{\varepsilon}$, $\boldsymbol{\varepsilon} \sim N(0, \sigma^2 I_n)$, 线性假设 $H_0: A\boldsymbol{\beta} = \mathbf{0}_{q \times 1}$, F 检验构造如下:

- Wald 检验: $W = (A\hat{\boldsymbol{\beta}})^T [\text{var}(A\hat{\boldsymbol{\beta}})]^{-1} (A\hat{\boldsymbol{\beta}})$
- F 检验: $F = W/q$
- 由约束最小二乘结果, 以投影表示 F

$$F = \frac{n-p}{q} \times \frac{\|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2}{\|\mathbf{y} - \hat{\mathbf{y}}\|^2}, \quad \hat{\mathbf{y}} = P_V \mathbf{y}, \quad \hat{\mathbf{y}}_0 = P_{V_0} \mathbf{y}$$

其中 $V = C(X)$ 和 V_0 分别为全模型下和原假设的自变量空间。

- 由引理2及 F 的投影表示, H_0 成立时, $F \sim \chi_{q, n-p}^2$ 。
- F 的其它表示: $F = \frac{n-p}{q} \times \frac{RSS_0 - RSS}{RSS} = \frac{n-p}{q} \times \frac{R^2 - R_0^2}{1 - R^2} = \frac{n-p}{q} \times \frac{R_p^2}{1 - R_p^2}$,
即 F 检验比较全模型和原假设下的残差平方和或比较决定系数,
 $R_p^2 = \frac{R^2 - R_0^2}{1 - R_0^2}$ 为部分决定系数 (参见P19)。
- $\mathbf{y} = X_1\boldsymbol{\beta}_1 + X_2\boldsymbol{\beta}_2 + \boldsymbol{\varepsilon}$, $H_0: \boldsymbol{\beta}_2 = \mathbf{0}_{q \times 1}$, $F = \|\hat{X}_2^\perp \hat{\boldsymbol{\beta}}_2\|^2 / q \hat{\sigma}^2$



部分回归系数的F检验

模型: $\mathbf{y}_{n \times 1} = X_{n \times p} \boldsymbol{\beta}_{p \times 1} + \boldsymbol{\varepsilon} = \mathbf{1}\beta_0 + X_1\boldsymbol{\beta}_1 + X_2\boldsymbol{\beta}_2 + \boldsymbol{\varepsilon}$, $\boldsymbol{\varepsilon} \sim N(0, \sigma^2 I_n)$, $V = C(\mathbf{1}, X_1, X_2)$

原假设 $H_0: \boldsymbol{\beta}_2 = \mathbf{0}_{q \times 1}$, 记 H_0 成立时的子模型为 $\mathbf{y} = \mathbf{1}\beta_0 + X_1\boldsymbol{\beta}_1 + \boldsymbol{\varepsilon}$, $V_0 = C(\mathbf{1}, X_1)$ 。

由命题2, H_0 的F检验统计量

$$F = \frac{\|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2 / q}{\|\mathbf{y} - \hat{\mathbf{y}}\|^2 / (n - p)}, \quad \hat{\mathbf{y}} = P_V \mathbf{y}, \quad \hat{\mathbf{y}}_0 = P_{V_0} \mathbf{y}$$

命题4. 假设模型 $\mathbf{y}_{n \times 1} = X_{n \times p} \boldsymbol{\beta}_{p \times 1} + \boldsymbol{\varepsilon} = \mathbf{1}\beta_0 + X_1\boldsymbol{\beta}_1 + X_2\boldsymbol{\beta}_2 + \boldsymbol{\varepsilon}$, $H_0: \boldsymbol{\beta}_2 = \mathbf{0}_{q \times 1}$, 记 $X_2^\perp = X_2 - P_{V_0} X_2 = X_2 - P_{\mathbf{1}, X_1} X_2$, 则 H_0 的F检验统计量为

$$F = \frac{\|X_2^\perp \hat{\boldsymbol{\beta}}_2\|^2}{q \hat{\sigma}^2} \stackrel{H_0}{\sim} F_{q, n-p},$$

其中 $\hat{\boldsymbol{\beta}}_2 = (X_2^{\perp T} X_2^\perp)^{-1} X_2^{\perp T} \mathbf{y}$ 为 $\boldsymbol{\beta}_2$ 的LS估计。

证明：注意到 $\hat{\mathbf{y}} = P_{(1, X_1, X_2)} \mathbf{y} = P_{(1, X_1, X_2^\perp)} \mathbf{y} = \hat{\mathbf{y}}_0 + P_{X_2^\perp} \mathbf{y} = \hat{\mathbf{y}}_0 + X_2^\perp \hat{\boldsymbol{\beta}}_2^\perp$

$$\Rightarrow \hat{\mathbf{y}} - \hat{\mathbf{y}}_0 = X_2^\perp \hat{\boldsymbol{\beta}}_2^\perp$$

另外， $\hat{\sigma}^2 = \|\mathbf{y} - \hat{\mathbf{y}}\|^2 / (n - p)$ ，所以

$$F = \frac{\|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2 / q}{\|\mathbf{y} - \hat{\mathbf{y}}\|^2 / (n - p)} = \frac{\|X_2^\perp \hat{\boldsymbol{\beta}}_2^\perp\|^2 / q}{\hat{\sigma}^2}$$

定义：假设 R^2 是全模型 $\mathbf{y}_{n \times 1} = X_{n \times p} \boldsymbol{\beta}_{p \times 1} + \boldsymbol{\varepsilon}$ 下的决定系数， R_0^2 是子模型 ($H_0: \boldsymbol{\beta}_2 = 0$ 成立时的模型) 下的决定系数，定义部分 (partial) 决定系数

$$R_p^2 = R_{y \cdot X_2 \cdot X_1}^2 = \frac{R^2 - R_0^2}{1 - R_0^2}$$

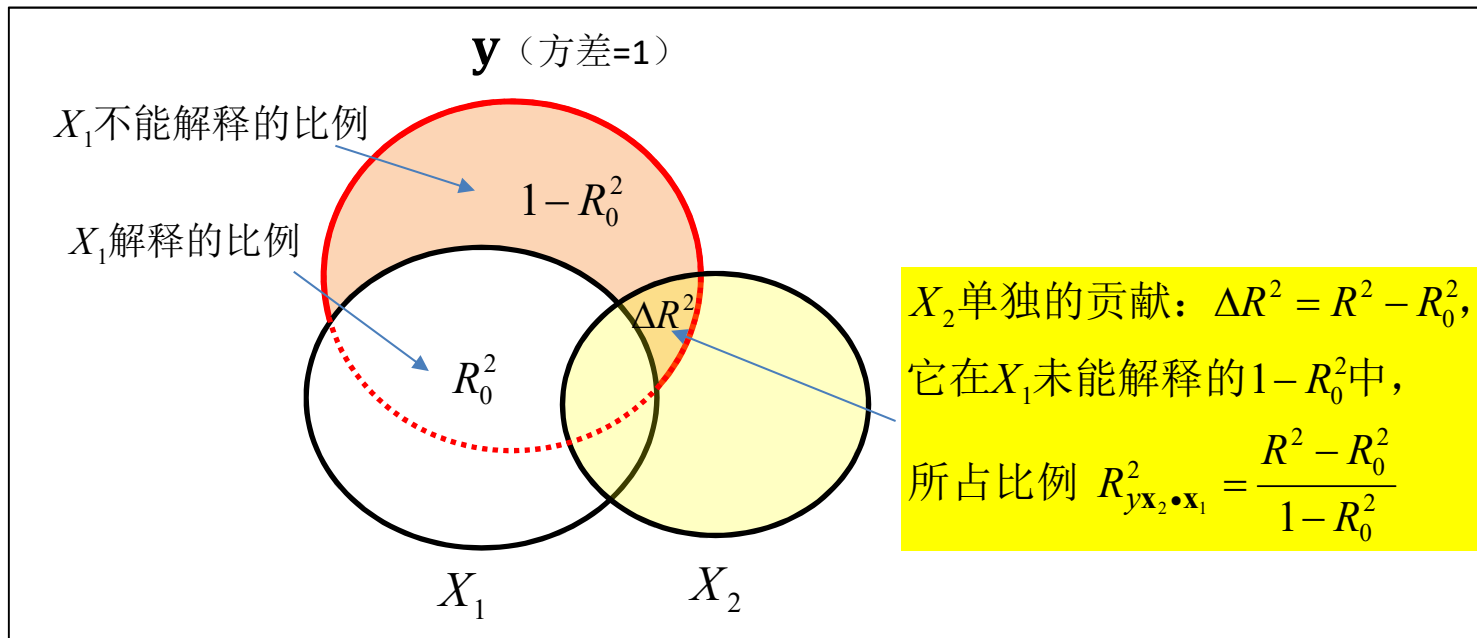
代表 \mathbf{y} 中 X_1 不能解释的部分中， X_2 所能解释的比例。

参见第4讲P12总体的部分决定系数：

$q = 1$ 时 (y 是随机变量)， Φ^2 是介于 0, 1 之间的实数，记作 $R_{y \cdot \mathbf{x} \cdot \mathbf{z}}^2$

$$R_{y \cdot \mathbf{x} \cdot \mathbf{z}}^2 = \frac{\sum_{y^\perp \mathbf{x}^\perp} \sum_{\mathbf{x}^\perp \mathbf{x}^\perp}^{-1} \sum_{\mathbf{x}^\perp y^\perp}}{\sum_{y^\perp y^\perp}} = \frac{\sum_{y \cdot \mathbf{x} \cdot \mathbf{z}} \sum_{\mathbf{x} \cdot \mathbf{z}}^{-1} \sum_{y \cdot \mathbf{z}}}{\sum_{y \cdot y \cdot \mathbf{z}}}$$

我们称之为控制随机向量 \mathbf{z} 条件下，响应变量 y 和随机向量 \mathbf{x} 之间的决定系数。



上图的具体解释如下:

原假设成立 ($H_0: \beta_2 = 0$) 时, 子模型 $\mathbf{y} = \mathbf{1}\beta_0 + X_1\beta_1 + \boldsymbol{\varepsilon}$ 的自变量 X_1 能解释响应方差的百分比为 R_0^2 , 不能解释的比例为 $1 - R_0^2$ 。

增加变量 X_2 后, 模型 $\mathbf{y} = \mathbf{1}\beta_0 + X_1\beta_1 + X_2\beta_2 + \boldsymbol{\varepsilon}$ 对响应的解释能力增加了 $\Delta R^2 = R^2 - R_0^2$, 其在子模型不能解释的部分 $1 - R_0^2$ 中的占比,

$$R_{y_{x_2 \cdot x_1}}^2 = \frac{\Delta R^2}{1 - R_0^2} = \frac{R^2 - R_0^2}{1 - R_0^2},$$

它度量了 X_2 的重要性, 可用来检验 β_2 是否等于 0。

$$\text{命题5. } R_{y\mathbf{x}_2 \cdot \mathbf{x}_1}^2 = \frac{S_{y2 \cdot 1} S_{22 \cdot 1}^{-1} S_{2y \cdot 1}}{S_{yy \cdot 1}}.$$

证明: $\hat{\mathbf{y}} - \hat{\mathbf{y}}_0 = X_2^\perp \hat{\boldsymbol{\beta}}_2 \Rightarrow \|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2 = \mathbf{y}^\top X_2^\perp (X_2^{\perp \top} X_2^\perp)^{-1} X_2^{\perp \top} \mathbf{y} = (n-1) S_{y2 \cdot 1} S_{22 \cdot 1}^{-1} S_{2y \cdot 1}$,

另外, $\|\mathbf{y} - \hat{\mathbf{y}}_0\|^2 = \|\mathbf{y} - \mathbf{1}\bar{y}\|^2 - \|\hat{\mathbf{y}}_0 - \mathbf{1}\bar{y}\|^2 = (n-1) S_{yy} - (n-1) S_{y1} S_{11}^{-1} S_{1y} = (n-1) S_{yy \cdot 1}$

$$\text{所以 } R_{y\mathbf{x}_2 \cdot \mathbf{x}_1}^2 = \frac{\|\hat{\mathbf{y}} - \hat{\mathbf{y}}_0\|^2}{\|\mathbf{y} - \hat{\mathbf{y}}_0\|^2} = \frac{S_{y2 \cdot 1} S_{22 \cdot 1}^{-1} S_{2y \cdot 1}}{S_{yy \cdot 1}}$$

结合上述命题3, 4有

命题5. 正态模型 $\mathbf{y}_{n \times 1} = X_{n \times p} \boldsymbol{\beta}_{p \times 1} + \boldsymbol{\varepsilon}$ 中, $X = (\mathbf{1}, X_1, X_2)$, $\boldsymbol{\beta} = (\beta_0, \boldsymbol{\beta}_1^\top, \boldsymbol{\beta}_2^\top)^\top$,

$$H_0: \boldsymbol{\beta}_2 = \mathbf{0}_{q \times 1} \text{ 的F检验统计量 } F = \frac{n-p}{q} \times \frac{R_p^2}{1-R_p^2} \stackrel{H_0}{\sim} F_{q, n-p},$$

其中 $R_p^2 \stackrel{\Delta}{=} R_{y\mathbf{x}_2 \cdot \mathbf{x}_1}^2 = \frac{S_{y2 \cdot 1} S_{22 \cdot 1}^{-1} S_{2y \cdot 1}}{S_{yy \cdot 1}}$ 为控制 X_1 时 \mathbf{y} 与 X_2 的部分决定系数。

我们已经看到，F检验有若干表示形式，对比如下

$H_0: \boldsymbol{\beta}_2 = \mathbf{0}_{q \times 1}$	
$F = \frac{n-p}{q} \times \frac{\ \hat{\mathbf{y}} - \hat{\mathbf{y}}_0\ ^2}{\ \mathbf{y} - \hat{\mathbf{y}}\ ^2}$	几何解释
$F = \frac{n-p}{q} \times \frac{RSS_0 - RSS}{RSS}$	几何解释, 软件使用
$F = \frac{\ X_2^\perp \hat{\boldsymbol{\beta}}_2\ ^2}{q \hat{\sigma}^2}$	直观
$F = \frac{n-p}{q} \times \frac{R_p^2}{1 - R_p^2}$	形式统一

• $q = 1$ 情形:

◦ $p = 2, q = 1$ 两个变量的相关性检验 $F = t^2 = (n-2) \frac{r^2}{1-r^2} \stackrel{H_0}{\sim} F_{1, n-2}$

◦ $p > 2, q = 1$ 两个变量的偏相关性检验 $F = t^2 = (n-p) \frac{r_{partial}^2}{1-r_{partial}^2} \stackrel{H_0}{\sim} F_{1, n-p}$

• $q > 1$ 情形:

◦ $q = p-1$: 回归方程的显著性检验 $F = \frac{n-p}{q} \times \frac{R^2}{1-R^2} \stackrel{H_0}{\sim} F_{p-1, n-p}$

◦ $1 < q < p-1$: $F = \frac{n-p}{q} \times \frac{R_p^2}{1-R_p^2}$

特例：回归方程的显著性检验

R输出结果summary中包括了两种重要情形：

- 所有自变量的F检验（回归方程的显著性检验）
- 每个回归系数的t检验

回归方程的显著性检验

检验所有自变量是否显著：

假设模型 $\mathbf{y} = X\boldsymbol{\beta} + \boldsymbol{\varepsilon} = \mathbf{1}\beta_0 + Z\mathbf{b} + \boldsymbol{\varepsilon}$, $\boldsymbol{\varepsilon} \sim N(0, \sigma^2 I_n)$,

零假设为 $H_0 : \mathbf{b} = \mathbf{0}_{(p-1) \times 1}$, 回归方程的显著性F检验：

$$F = \frac{\|Z_c \hat{\mathbf{b}}\|^2}{(p-1)\hat{\sigma}^2} = \frac{n-p}{p-1} \times \frac{R^2}{1-R^2} \sim_{H_0} F_{p-1, n-p}$$

其中 Z_c 为 Z 的中心化, $\hat{\mathbf{b}}$, $\hat{\sigma}^2$ 为LS估计, R^2 为决定系数。

$F \geq F_{p-1, n-p}(1-\alpha)$ 时在水平 α 下否定原假设。

零假设下的决定系数 $R_0^2 = 0$

回归方程显著性检验由决定系数唯一决定： $F = \frac{n-p}{q} \times \frac{R^2}{1-R^2}$

特例：单个回归系数的t检验

单个回归系数的t检验
(\sqrt{F} 检验)

假设模型 $\mathbf{y} = X\boldsymbol{\beta} + \boldsymbol{\varepsilon} = \mathbf{1}\beta_0 + \mathbf{x}_1\beta_1 + \dots + \mathbf{x}_{p-1}\beta_{p-1} + \boldsymbol{\varepsilon}$, $\boldsymbol{\varepsilon} \sim N(0, \sigma^2 I_n)$,

记 $\mathbf{x}_k^\perp = \mathbf{x}_k - P_{X_{(-k)}} \mathbf{x}_k$, $X_{(-k)}$ 为 X 除第 k 列之外的构成的矩阵,

LS估计 $\hat{\beta}_k = (\mathbf{x}_k^{\perp T} \mathbf{x}_k^\perp)^{-1} \mathbf{x}_k^{\perp T} \mathbf{y}$, $\text{var}(\hat{\beta}_k | X) = \sigma^2 (\mathbf{x}_k^{\perp T} \mathbf{x}_k^\perp)^{-1} = \sigma^2 / \|\mathbf{x}_k^\perp\|^2$.

$H_0: \beta_k = 0$, $k \geq 1$ 的 F 检验:

$$F = \frac{\|\mathbf{x}_k^\perp \hat{\beta}_k\|^2}{\hat{\sigma}^2} = \left(\frac{\hat{\beta}_k}{\hat{\sigma} / \|\mathbf{x}_k^\perp\|} \right)^2 \sim_{H_0} F_{1, n-p}$$

这等价于 t 检验

$$t = \pm \sqrt{F} = \frac{\hat{\beta}_k}{\hat{\sigma} / \|\mathbf{x}_k^\perp\|} \sim_{H_0} t_{n-p}^\circ$$

$t = \text{估计值} \div \text{标准差}$

例2. 待遇上的性别歧视案例 (数据集salary: alr4).有大学女教师反映女性在待遇上受到了歧视，为此收集了一批数据，包括每个大学教师的工资Salary，性别Sex, 职称Rank和工龄Year。Salary~Sex得到Sex的效应是接近显著的(p=0.07)，但控制其它变量时Sex不再显著(p=0.46):

$$\text{Salary} = \beta_0 + \beta_1 \text{Sex} + \beta_2 \text{Rank} + \beta_3 \text{Year} + \varepsilon$$

```
lm(formula = Salary ~ Sex + Rank + Year, data = salary)

Coefficients:
                Estimate Std. Error t value Pr(>|t|)
(Intercept) 11011.76    966.95   11.388 3.03e-15 ***
Sex          603.77     811.20    0.744 0.46
Rank         4747.18    452.58   10.489 5.18e-14 ***
Year         393.86     74.53    5.285 3.04e-06 ***
---
Residual standard error: 2398 on 48 degrees of freedom
Multiple R-squared: 0.8454, Adjusted R-squared: 0.8358
F-statistic: 87.51 on 3 and 48 DF, p-value: < 2.2e-16
```

$t = \text{估计值} \div \text{标准差}$

$t = 603.77 / 811.20 = 0.744$

回归方程的显著性检验

单个回归系数的t检验

在R软件中，summary没有输出的检验需要使用anova函数，比较完全模型和零模型

例如，同时检验 Rank, Year 的显著性： $H_0 : \beta_2 = \beta_3 = 0$ 。

```
> m1 = lm(Salary~Sex+Rank+Year, data=salary) #完全模型
> m0 = lm(Salary~Sex, data=salary) #零模型
> anova(m0, m1) #方差分析anova: 比较m0,m1
Analysis of Variance Table

Model 1: Salary ~ Sex
Model 2: Salary ~ Sex + Rank + Year
  Res.Df  RSS      Df Sum of Sq  F      Pr(>F)
1     50 1671623638
2     48 276016717  2 1395606921 121.35 < 2.2e-16 ***
```

$$F = \frac{n-p}{k} \times \frac{RSS_0 - RSS}{RSS} = \frac{52-4}{2} \times \frac{1671623638 - 276016717}{276016717} = 121.35$$