

第五讲 线性回归模型

2023.10.13

$$y = a + \mathbf{b}^\top \mathbf{x} + \varepsilon, \quad \varepsilon \perp \mathbf{x}, \quad \varepsilon \sim (0, \sigma^2)$$

线性回归模型

为了研究 \mathbf{x} , \mathbf{y} 之间是否存在因果关系, 所有影响 \mathbf{y} 的其它因素需要与 \mathbf{x} 独立 (即不存在干扰因素)。所以, 即使控制变量, 偏相关分析和去相关化也不足以推断因果关系, 这是因为不相关不等同于独立。

线性回归模型

定义1: (一元)线性回归模型假设响应变量 \mathbf{y} 和自变量向量 \mathbf{x} 满足方程:

$$\mathbf{y} = a + \mathbf{b}^T \mathbf{x} + \varepsilon,$$

其中误差项 ε 是不可观测的随机变量, 满足Gauss - Markov(GM)假设

- (1) $E(\varepsilon) = 0$; (截距 a 可识别)
- (2) $\text{var}(\varepsilon) = \sigma^2$ (方差齐性, Homoscedasticity)
- (3) ε 与 \mathbf{x} 独立 (外生性, Exogeneity)

- 误差项 ε 代表了除了自变量 \mathbf{x} 之外所有其它影响 \mathbf{y} 的因素。
- 模型假设 $\varepsilon \perp \mathbf{x}$ (ε 与 \mathbf{x} 独立), 即 ε 不是干扰因素, 是推断因果必需的。
- 条件(1)、(2)简记作 $\varepsilon \sim (0, \sigma^2)$
- (\mathbf{y}, \mathbf{x}) 服从多元正态时, GM假设都成立。

命题1. 若 (y, \mathbf{x}) 满足线性模型的Gauss - Markov假设(1),(2),(3), 则

(i) $E(y | \mathbf{x}) = a + \mathbf{b}^\top \mathbf{x}$ (回归函数线性)

(ii) $\text{var}(y | \mathbf{x}) = \sigma^2$ (条件方差常数)

证明: 因为 ε 与 \mathbf{x} 独立, 所以 $E(\varepsilon | \mathbf{x}) = E(\varepsilon) = 0$, 所以

$$E(y | \mathbf{x}) = E(a + \mathbf{b}^\top \mathbf{x} + \varepsilon | \mathbf{x}) = a + \mathbf{b}^\top \mathbf{x} + E(\varepsilon | \mathbf{x}) = a + \mathbf{b}^\top \mathbf{x},$$

$$\text{var}(y | \mathbf{x}) = \text{var}(a + \mathbf{b}^\top \mathbf{x} + \varepsilon | \mathbf{x}) = \text{var}(\varepsilon | \mathbf{x}) = \text{var}(\varepsilon) = \sigma^2.$$

注: 线性回归模型蕴含了条件期望

$$E(y|\mathbf{x}) = a + \mathbf{b}^\top \mathbf{x}$$

关于 \mathbf{x} 线性。条件期望 $E(y|\mathbf{x})$ 也称为回归函数, 是平方损失下所有 \mathbf{x} 的函数中对 y 的最佳逼近(参见P6)。所以线性回归模型实际上假设了“ \mathbf{x} 的线性函数是所有 y 的函数 $g(\mathbf{x})$ 逼近中最佳的逼近”。

命题1中的(i),(ii) 与定义1中的(1)、(2)、(3)几乎等价，后者更强：

若(i),(ii)成立，令 $\varepsilon = y - E(y | \mathbf{x}) = y - (a + \mathbf{b}^\top \mathbf{x})$ ，则我们有

$$y = a + \mathbf{b}^\top \mathbf{x} + \varepsilon,$$

下面验证 ε 满足GM假设(1),(2),以及(3)的弱版本：

$$(1) E(\varepsilon) = E(y - E(y | \mathbf{x})) = 0,$$

$$(2) \text{var}(\varepsilon) = \text{var}(y - a - \mathbf{b}^\top \mathbf{x})$$

$$= \text{var}(E(y - a - \mathbf{b}^\top \mathbf{x} | \mathbf{x})) + E(\text{var}(y - a - \mathbf{b}^\top \mathbf{x} | \mathbf{x}))$$

$$= 0 + E(\text{var}(y | \mathbf{x})) = \sigma^2.$$

(3*)由条件期望的性质， $\varepsilon = y - E(y | \mathbf{x})$ 与 \mathbf{x} 不相关（但不一定独立）。

我们只需在(i),(ii)基础上增加假设" $y - E(y | \mathbf{x})$ 与 \mathbf{x} 独立"，即得到等价定义

模型的等价定义

定义2: 假设 y 是响应变量, \mathbf{x} 是自变量(向量), $E(y | \mathbf{x})$ 称为回归函数, 线性回归模型假设:

(i) 线性回归函数: $E(y | \mathbf{x}) = a + \mathbf{b}^T \mathbf{x}$.

(ii) 方差常数/齐性: $\text{var}(y | \mathbf{x}) = \sigma^2$.

(iii) $y - E(y | \mathbf{x})$ 与 \mathbf{x} 独立。

注1: 一般教材通常假设 \mathbf{x} 是给定的常数, 并以条件(i)、(ii)或GM假设(1)、(2)定义线性模型, 而不假设 ε 与 \mathbf{x} 的独立性。

注2: 其它(非线性)回归模型通常对回归函数做假设, 比如

(1) logistic回归: 响应变量 y 是伯努利变量, 它与自变量 \mathbf{x} 有关, logistic回归模型假设 $y | \mathbf{x} \sim B(1, \pi(\mathbf{x}))$,

$$\pi(\mathbf{x}) = P(y = 1 | \mathbf{x}) = 1 - P(y = 0 | \mathbf{x}) = E(y | \mathbf{x}) = \frac{\exp(a + \mathbf{b}^T \mathbf{x})}{1 + \exp(a + \mathbf{b}^T \mathbf{x})}$$

(2) Poisson回归: 假设 y 是计数变量, 服从Poisson分布 $Pois(\lambda(\mathbf{x}))$,

$$\lambda(\mathbf{x}) = E(y | \mathbf{x}) = \exp(a + \mathbf{b}^T \mathbf{x}).$$

向量空间中的投影

向量空间或线性空间 V 是一个定义了加法和数乘的封闭集合，集合的元素称作向量。假设赋予 V 内积： $\langle v, u \rangle$ ， $u, v \in V$ 。假设 $U \subset V$ 是向量子空间，则任何 $v \in V$ 在 U 上的正交投影（记作 $\hat{v} \in U$ ）满足

$$\langle v - \hat{v}, u \rangle = 0, \forall u \in U$$

最常见的向量空间是函数空间，包括 R^n 和随机变量空间，以及量子力学的量子空间。

关于回归函数


定义(条件期望/回归函数)： $\varphi(\mathbf{x})$ 是 y 给定 \mathbf{x} 的条件期望，记作 $E(y|\mathbf{x})$ ，若对任何可测 $g(\mathbf{x})$ ，内积 $\langle y - \varphi(\mathbf{x}), g(\mathbf{x}) \rangle = E(y - \varphi(\mathbf{x}))g(\mathbf{x}) = 0$ 。

定义表明， $y - \varphi(\mathbf{x}) \perp L^2(\sigma(\mathbf{x}))$ ，其中

$$L^2(\sigma(\mathbf{x})) = \{g(\mathbf{x}) : g \text{ 可测}, E g(\mathbf{x})^2 < \infty\}$$

是所有 $\sigma(\mathbf{x})$ 可测函数组成的随机变量空间。因此， $E(y|\mathbf{x})$ 是 y 在 \mathbf{x} 的函数组成的空间上的正交投影，从而是 \mathbf{x} 的所有可测函数中对 y 的最佳逼近：

$$E(y|\mathbf{x}) = \operatorname{argmin}_g E(y - g(\mathbf{x}))^2 \quad (*)$$



条件期望 $E(y|\mathbf{x})$ 是 y 在所有 \mathbf{x} 的函数组成空间上的正交投影。

证明(*):这是正交投影的基本性质,但这里不妨直接证明如下:

首先,注意到 $\min_{a \in R} E(y-a)^2$ 的最小值在 $a = E(y)$ 处达到。

其次,为了极小化 $\min_g E(y-g(\mathbf{x}))^2$,只需极小化 $E[(y-g(\mathbf{x}))^2 | \mathbf{x}]$,当 \mathbf{x} 给定时,常数 $g(\mathbf{x})$ 等于 y 的期望 $E(y | \mathbf{x})$ 时达到极小。

性质:假设 y 是任一随机变量, \mathbf{x} 是随机向量,则

(1) Law of total expectation/Tower property: $E(E(y | \mathbf{x})) = E(y)$ 。

(2) Law of total variance (方差分解/勾股定理):

$$\text{var}(y) = \text{var}[E(y | \mathbf{x})] + E[\text{var}(y | \mathbf{x})]$$

因此定义决定系数

$$\Phi = \frac{\text{var}(E(y | \mathbf{x}))}{\text{var}(y)}$$

证明: (1) 条件期望定义中取 $g(\mathbf{x}) = 1$,则 $E[y - E(y | \mathbf{x})] \times 1 = 0$ 。

(2): 令 $\varepsilon = y - E(y | \mathbf{x})$,定义中取 $g(\mathbf{x}) = x_i$, $E[y - E(y | \mathbf{x})]x_i = 0$

即 ε 与 x_i 不相关, ε 与 \mathbf{x} 不相关,正交分解 $y = E(y | \mathbf{x}) + \varepsilon$ 两边同时求方差:

$$\text{var}(y) = \text{var}[E(y | \mathbf{x})] + \text{var}[\varepsilon],$$

而误差的方差 $\text{var}[\varepsilon] = \text{var}[y - E(y | \mathbf{x})] = \dots = E[\text{var}(y | \mathbf{x})]$ 。

参数的含义

命题2. 假设线性回归模型 (y 随机变量, $\mathbf{x}_{p \times 1}$ 自变量):

$$y = a + \mathbf{b}^T \mathbf{x} + \varepsilon, E(\varepsilon) = 0, \text{var}(\varepsilon) = \sigma^2, \varepsilon \text{与} \mathbf{x} \text{独立}$$

则参数 a , \mathbf{b} , σ^2 由 y, \mathbf{x} 的均值和方差决定:

$$\mathbf{b} = \Sigma_{\mathbf{xx}}^{-1} \Sigma_{\mathbf{xy}}, a = \mu_y - \mathbf{b}^T \boldsymbol{\mu}_x, \sigma^2 = \Sigma_{yy \cdot \mathbf{x}} = \Sigma_{yy} (1 - \Phi)$$

其中 $\Phi = \frac{\text{var}(\mathbf{b}^T \mathbf{x})}{\text{var}(y)} = \Sigma_{y\mathbf{x}} \Sigma_{\mathbf{xx}}^{-1} \Sigma_{\mathbf{xy}} / \Sigma_{yy}$ 为决定系数。

证: ε 与 \mathbf{x} 独立 $\Rightarrow \varepsilon = y - a - \mathbf{b}^T \mathbf{x}$ 与 \mathbf{x} 不相关, 是 y 的去相关化, 所以必定

$\mathbf{b}^T = \Sigma_{y\mathbf{x}} \Sigma_{\mathbf{xx}}^{-1}$, 再次验证如下:

$$0 = \text{cov}(\varepsilon, \mathbf{x}) = \text{cov}(y - a - \mathbf{b}^T \mathbf{x}, \mathbf{x}) = \Sigma_{y\mathbf{x}} - \mathbf{b}^T \Sigma_{\mathbf{xx}} \Rightarrow \mathbf{b} = \Sigma_{\mathbf{xx}}^{-1} \Sigma_{\mathbf{xy}}$$

$$\text{方程两边求均值: } \mu_y = a + \mathbf{b}^T \boldsymbol{\mu}_x \Rightarrow a = \mu_y - \mathbf{b}^T \boldsymbol{\mu}_x = \mu_y - \Sigma_{y\mathbf{x}} \Sigma_{\mathbf{xx}}^{-1} \boldsymbol{\mu}_x$$

$$\text{方程两边求方差: } \Sigma_{yy} = \text{var}(\mathbf{b}^T \mathbf{x}) + \text{var}(\varepsilon) = \mathbf{b}^T \Sigma_{\mathbf{xx}} \mathbf{b} + \sigma^2 \Rightarrow \sigma^2 = \Sigma_{yy \cdot \mathbf{x}}$$

$$\Phi = \text{var}(\mathbf{b}^T \mathbf{x}) / \text{var}(y) = \Sigma_{y\mathbf{x}} \Sigma_{\mathbf{xx}}^{-1} \Sigma_{\mathbf{xy}} / \Sigma_{yy} \Rightarrow \sigma^2 = \Sigma_{yy \cdot \mathbf{x}} = \Sigma_{yy} (1 - \Phi)。$$

注1: 由命题2, 线性回归模型以均值和方差可表示为:

$$y = a + \Sigma_{yx} \Sigma_{xx}^{-1} \mathbf{x} + \boldsymbol{\varepsilon}, \quad \boldsymbol{\varepsilon} \text{ 与 } \mathbf{x} \text{ 独立}$$

与去相关化类比几乎相同:

$$y = \Sigma_{yx} \Sigma_{xx}^{-1} \mathbf{x} + y^\perp, \quad y^\perp \text{ 与 } \mathbf{x} \text{ 不相关}$$

其中 y^\perp 可看作是误差项, 它与 \mathbf{x} 不相关, 但不一定独立

- 因为要求 $E(\boldsymbol{\varepsilon}) = 0$, 回归模型多出了常数项 \mathbf{a} (不影响相关性和独立性);
- 回归模型假设 $\boldsymbol{\varepsilon} = \mathbf{y} - \Sigma_{yx} \Sigma_{xx}^{-1} \mathbf{x} - \mathbf{a}$ 与 \mathbf{x} 独立, 比“ y^\perp 与 \mathbf{x} 不相关”要求更高。
- 两个变量不相关可以通过去相关化做到, 而独立性只是个假设, 难以做到(无法做到)。

注2： 响应变量 \mathbf{y} 是向量的情形，线性模型类似：

定义：（多元线性回归模型）

假设随机向量 $\mathbf{y}_{q \times 1}, \mathbf{x}_{p \times 1}$ 满足：

$$\mathbf{y}_{q \times 1} = \mathbf{a}_{q \times 1} + \mathbf{B}_{q \times p} \mathbf{x}_{p \times 1} + \boldsymbol{\varepsilon}_{q \times 1}, \quad \boldsymbol{\varepsilon} \sim (0, \Sigma), \quad \boldsymbol{\varepsilon} \text{与} \mathbf{x} \text{独立}$$

称为多元线性回归模型。其中 \mathbf{y} 称为响应， \mathbf{x} 称为自变量，可观测； $\boldsymbol{\varepsilon}$ 不可观测，一般称为误差。 \mathbf{a} ， \mathbf{B} ， Σ 是参数，它们完全由 \mathbf{y}, \mathbf{x} 的均值和方差决定： $\mathbf{B} = \Sigma_{\mathbf{y}\mathbf{x}} \Sigma_{\mathbf{x}\mathbf{x}}^{-1}$ ， $\mathbf{a} = \boldsymbol{\mu}_{\mathbf{y}} - \mathbf{B} \boldsymbol{\mu}_{\mathbf{x}}$ ， $\Sigma = \Sigma_{\mathbf{y}\mathbf{y} \cdot \mathbf{x}}$ 。

今后一般不再考虑多元回归模型。

考虑 $y = a + \mathbf{b}^T \mathbf{x} + \varepsilon$ 中部分变量的回归系数。假设 $\mathbf{x} = \begin{pmatrix} \mathbf{x}_1 \\ \mathbf{x}_2 \end{pmatrix}$, $\mathbf{b} = \begin{pmatrix} \mathbf{b}_1 \\ \mathbf{b}_2 \end{pmatrix}$,

其中 \mathbf{x}_1 是感兴趣的变量, \mathbf{x}_2 是控制变量 / 干扰因素。

命题3. 假设模型:

$$y = a + \mathbf{b}^T \mathbf{x} + \varepsilon = a + \mathbf{b}_1^T \mathbf{x}_1 + \mathbf{b}_2^T \mathbf{x}_2 + \varepsilon, \quad \varepsilon \sim (0, \sigma^2) \text{ 与 } \mathbf{x} \text{ 独立}$$

其中 $\mathbf{x} = \begin{pmatrix} \mathbf{x}_1 \\ \mathbf{x}_2 \end{pmatrix}$ 独立, $\mathbf{b} = \begin{pmatrix} \mathbf{b}_1 \\ \mathbf{b}_2 \end{pmatrix}$ 。令 $\mathbf{x}_1^\perp = \mathbf{x}_1 - \Sigma_{12} \Sigma_{22}^{-1} \mathbf{x}_2$, $y^\perp = y - \Sigma_{y2} \Sigma_{22}^{-1} \mathbf{x}_2$, 则

(1) $y^\perp = a + \mathbf{b}_1^T \mathbf{x}_1^\perp + \varepsilon$, $E(\varepsilon) = 0$, $\text{var}(\varepsilon) = \sigma^2$, ε 与 \mathbf{x}_1^\perp 独立.

(2) $\mathbf{b}_1 = \Sigma_{11 \cdot 2}^{-1} \Sigma_{1y \cdot 2}$

(3) 当 \mathbf{x}_1 是随机变量时, $b_1 \propto \rho_{1y \cdot 2}$ 与偏相关系数成正比。

(4) 部分 / 偏决定系数 $R_{1y \cdot 2}^2 = \frac{\text{var}(\mathbf{b}_1^T \mathbf{x}_1^\perp)}{\text{var}(y^\perp)} = \frac{\Sigma_{y1 \cdot 2} \Sigma_{11 \cdot 2}^{-1} \Sigma_{1y \cdot 2}}{\Sigma_{yy \cdot 2}}$.

证明： (1) 原方程为

$$y^\perp + \Sigma_{y_2} \Sigma_{22}^{-1} \mathbf{x}_2 = y = a + \mathbf{b}_1^\top (\mathbf{x}_1^\perp + \Sigma_{12} \Sigma_{22}^{-1} \mathbf{x}_2) + \mathbf{b}_2^\top \mathbf{x}_2 + \varepsilon$$

所以

$$y^\perp = a + \mathbf{b}_1^\top \mathbf{x}_1^\perp + \underbrace{(\mathbf{b}_1^\top \Sigma_{12} \Sigma_{22}^{-1} + \mathbf{b}_2^\top - \Sigma_{y_2} \Sigma_{22}^{-1})}_{\text{记为 } \mathbf{c}^\top} \mathbf{x}_2 + \varepsilon = a + \mathbf{b}_1^\top \mathbf{x}_1^\perp + \underline{\mathbf{c}^\top \mathbf{x}_2} + \varepsilon$$

其中下划线 $\mathbf{c}^\top \mathbf{x}_2$ 部分一定为0。

这是因为方程中的其它各项都与 \mathbf{x}_2 不相关，

$$0 = \text{cov}(y^\perp - a - \mathbf{b}_1^\top \mathbf{x}_1^\perp - \varepsilon, \mathbf{x}_2) = \text{cov}(\mathbf{c}^\top \mathbf{x}_2, \mathbf{x}_2) = \mathbf{c}^\top \Sigma_{22}$$

$\Rightarrow \mathbf{c}^\top = 0$ ，因此我们有

$$y^\perp = a + \mathbf{b}_1^\top \mathbf{x}_1^\perp + \varepsilon$$

(2) 对于模型(1)

$y^\perp = a + \mathbf{b}_1^\top \mathbf{x}_1^\perp + \varepsilon$, $E(\varepsilon) = 0$, $\text{var}(\varepsilon) = \sigma^2$, ε 与 \mathbf{x}_1^\perp 独立
应用命题2, 我们有

$$\mathbf{b}_1 = \Sigma_{\mathbf{x}_1^\perp \mathbf{x}_1^\perp}^{-1} \Sigma_{\mathbf{x}_1^\perp y^\perp} = \Sigma_{11 \cdot 2}^{-1} \Sigma_{1y \cdot 2}$$

(2) 也可利用分块矩阵的逆矩阵公式证明如下:

由命题2, 我们知 $y = a + \mathbf{b}^\top \mathbf{x} + \varepsilon$ 中 $\mathbf{b} = \begin{pmatrix} \mathbf{b}_1 \\ \mathbf{b}_2 \end{pmatrix} = \Sigma_{\mathbf{xx}}^{-1} \Sigma_{\mathbf{xy}}$,

其中 $\Sigma_{\mathbf{xx}} = \begin{pmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{pmatrix}$, $\Sigma_{\mathbf{xy}} = \begin{pmatrix} \Sigma_{1y} \\ \Sigma_{2y} \end{pmatrix}$, 所以

$$\begin{aligned} \begin{pmatrix} \mathbf{b}_1 \\ \mathbf{b}_2 \end{pmatrix} &= \begin{pmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{pmatrix}^{-1} \begin{pmatrix} \Sigma_{1y} \\ \Sigma_{2y} \end{pmatrix} \\ &= \begin{pmatrix} \Sigma_{11 \cdot 2}^{-1} & -\Sigma_{11 \cdot 2}^{-1} \Sigma_{12} \Sigma_{22}^{-1} \\ * & * \end{pmatrix} \begin{pmatrix} \Sigma_{1y} \\ \Sigma_{2y} \end{pmatrix} = \begin{pmatrix} \Sigma_{11 \cdot 2}^{-1} \Sigma_{1y} - \Sigma_{11 \cdot 2}^{-1} \Sigma_{12} \Sigma_{22}^{-1} \Sigma_{2y} \\ * \end{pmatrix} \end{aligned}$$

故 $\mathbf{b}_1 = \Sigma_{11 \cdot 2}^{-1} \Sigma_{1y} - \Sigma_{11 \cdot 2}^{-1} \Sigma_{12} \Sigma_{22}^{-1} \Sigma_{2y} = \Sigma_{11 \cdot 2}^{-1} (\Sigma_{1y} - \Sigma_{12} \Sigma_{22}^{-1} \Sigma_{2y}) = \Sigma_{11 \cdot 2}^{-1} \Sigma_{1y \cdot 2}$

(3) 特别地, 当 \mathbf{x}_1 是随机变量时, $b_1 = \Sigma_{y1\cdot 2} / \Sigma_{11\cdot 2}$

$$= \frac{\Sigma_{y1\cdot 2}}{\sqrt{\Sigma_{11\cdot 2}} \sqrt{\Sigma_{yy\cdot 2}}} \times \frac{\sqrt{\Sigma_{yy\cdot 2}}}{\sqrt{\Sigma_{11\cdot 2}}} \propto \rho_{1y\cdot 2}$$

(4) 部分 / 偏决定系数 $R_{y1\cdot 2}^2$ 即模型(1)的决定系数

$$R_{y1\cdot 2}^2 = \frac{\text{var}(\mathbf{b}_1^\top \mathbf{x}_1^\perp)}{\text{var}(y^\perp)} = \frac{\mathbf{b}_1^\top \text{var}(\mathbf{x}_1^\perp) \mathbf{b}_1}{\text{var}(y^\perp)} = \frac{\mathbf{b}_1^\top \Sigma_{11\cdot 2} \mathbf{b}_1}{\Sigma_{yy\cdot 2}} = \frac{\Sigma_{y1\cdot 2} \Sigma_{11\cdot 2}^{-1} \Sigma_{1y\cdot 2}}{\Sigma_{yy\cdot 2}}$$

参数的 矩估计

假设样本 (y_i, \mathbf{x}_i) , $i = 1, \dots, n$ 来自于线性模型

$$y = a + \mathbf{b}^\top \mathbf{x} + \varepsilon, \quad E(\varepsilon) = 0, \quad \text{var}(\varepsilon) = \sigma^2, \quad \varepsilon \text{与} \mathbf{x} \text{独立}$$

假设样本方差矩阵和样本均值为

$$S = \begin{pmatrix} S_{yy} & S_{yx} \\ S_{xy} & S_{xx} \end{pmatrix}, \quad \begin{pmatrix} \bar{y} \\ \bar{\mathbf{x}} \end{pmatrix}$$

由命题2知, 参数 a , \mathbf{b} , σ^2 的矩估计可取为:

$$\begin{cases} \hat{\mathbf{b}} = S_{xx}^{-1} S_{xy}, \\ \hat{a} = \bar{y} - \hat{\mathbf{b}}^\top \bar{\mathbf{x}}, \\ \tilde{\sigma}^2 = S_{yy \cdot \mathbf{x}} = S_{yy} - S_{yx} S_{xx}^{-1} S_{xy}. \end{cases}$$

另外, $R^2 = \hat{\Phi} = S_{yx} S_{xx}^{-1} S_{xy} / S_{yy}$ 。

注: 后面将会看到, 除了误差方差之外, 所有参数的最小二乘估计等于上述矩估计。误差方差的最小二乘估计

$$\hat{\sigma}^2 = \frac{n-1}{n-p} \tilde{\sigma}^2 \approx \tilde{\sigma}^2$$