

课程主页: <http://staff.ustc.edu.cn/~ynyang/2022>

第五讲 线性回归模型

2022.9.30

线性回归模型形式上与去相关化相同，但假设误差与自变量独立（而不是不相关）。

Recap

$\mathbf{y}_{q \times 1}$ 与 $\mathbf{x}_{p \times 1}$ 整体相关性（典则相关系数或决定系数）

去相关化: $\mathbf{y}^\perp = \mathbf{y} - \Sigma_{\mathbf{y}\mathbf{x}}\Sigma_{\mathbf{x}\mathbf{x}}^{-1}\mathbf{x} = \mathbf{y} - B\mathbf{x}$

1) 正交分解: $\mathbf{y} = \Sigma_{\mathbf{y}\mathbf{x}}\Sigma_{\mathbf{x}\mathbf{x}}^{-1}\mathbf{x} + \mathbf{y}^\perp = B\mathbf{x} + \mathbf{y}^\perp$, \mathbf{y}^\perp 与 \mathbf{x} 不相关
(线性模型有更强的假设: $\mathbf{y} = \mathbf{a} + B\mathbf{x} + \boldsymbol{\varepsilon}$, $\boldsymbol{\varepsilon}$ 与 \mathbf{x} 独立)

2) 方差分解: $\Sigma_{\mathbf{y}\mathbf{y}} = \Sigma_{\mathbf{y}\mathbf{x}}\Sigma_{\mathbf{x}\mathbf{x}}^{-1}\Sigma_{\mathbf{x}\mathbf{y}} + \Sigma_{\mathbf{y}\mathbf{y}\cdot\mathbf{x}}$

\mathbf{x} 解释 \mathbf{y} 的方差的比例 ($q \times q$ 矩阵):

$$\Phi = \Phi_{\mathbf{y}\mathbf{x}} = \Sigma_{\mathbf{y}\mathbf{y}}^{-1/2} (\Sigma_{\mathbf{y}\mathbf{x}}\Sigma_{\mathbf{x}\mathbf{x}}^{-1}\Sigma_{\mathbf{x}\mathbf{y}})\Sigma_{\mathbf{y}\mathbf{y}}^{-1/2}$$

3) \mathbf{x} 和 \mathbf{y} 的整体相关性:

$q = 1$: 决定系数 $R^2 = \Phi$.

$q > 1$: 典则相关系数 $\sqrt{\lambda_{\max}(\Phi)}$

$\mathbf{y}_{q \times 1}$ 与 $\mathbf{x}_{p \times 1} = \begin{pmatrix} \mathbf{x}_1 \\ \mathbf{x}_2 \end{pmatrix}$ 的局部相关性: 控制 \mathbf{x}_2 时, \mathbf{y} 与 \mathbf{x}_1 的相关性

□ \mathbf{y} 与 \mathbf{x}_1 关于 \mathbf{x}_2 去相关化:

$$\mathbf{y}^\perp = \mathbf{y} - \Sigma_{\mathbf{y}\mathbf{2}} \Sigma_{\mathbf{2}\mathbf{2}}^{-1} \mathbf{x}_2, \quad \mathbf{x}_1^\perp = \mathbf{x}_1 - \Sigma_{\mathbf{1}\mathbf{2}} \Sigma_{\mathbf{2}\mathbf{2}}^{-1} \mathbf{x}_2$$

$$\Sigma_{\mathbf{y}\mathbf{2}} = \Sigma_{\mathbf{y}\mathbf{x}_2}$$

$$\Sigma_{\mathbf{2}\mathbf{2}} = \Sigma_{\mathbf{x}_2\mathbf{x}_2}$$

□ 考虑 \mathbf{y}^\perp , \mathbf{x}_1^\perp 的相关性 (应用上页 1)-3))。

具体如下:

1) 去相关化 (\mathbf{y}^\perp 中消去 \mathbf{x}_1^\perp): $(\mathbf{y}^\perp)^\perp = \mathbf{y}^\perp - \Sigma_{\mathbf{y}^\perp \mathbf{x}_1^\perp} \Sigma_{\mathbf{x}_1^\perp \mathbf{x}_1^\perp}^{-1} \mathbf{x}_1^\perp$

方差分解: $\Sigma_{\mathbf{y}\mathbf{y}\cdot\mathbf{2}} = \Sigma_{\mathbf{y}\mathbf{1}\cdot\mathbf{2}} \Sigma_{\mathbf{1}\mathbf{1}\cdot\mathbf{2}}^{-1} \Sigma_{\mathbf{1}\mathbf{y}\cdot\mathbf{2}} + \Sigma_{\mathbf{y}\mathbf{y}\cdot\mathbf{x}}$

2) \mathbf{x}_1^\perp 解释 \mathbf{y}^\perp 的方差的“比例”

$$\Phi^\perp = \Phi_{\mathbf{y}\mathbf{1}\cdot\mathbf{2}} = \Sigma_{\mathbf{y}\mathbf{y}\cdot\mathbf{2}}^{-1/2} (\Sigma_{\mathbf{y}\mathbf{1}\cdot\mathbf{2}} \Sigma_{\mathbf{1}\mathbf{1}\cdot\mathbf{2}}^{-1} \Sigma_{\mathbf{1}\mathbf{y}\cdot\mathbf{2}}) \Sigma_{\mathbf{y}\mathbf{y}\cdot\mathbf{2}}^{-1/2}$$

3) \mathbf{y} 与 \mathbf{x}_1 的局部相关性:

$q = 1$: $R_{\mathbf{y}\mathbf{1}\cdot\mathbf{2}}^2 \triangleq \Phi^\perp$ 部分决定系数

$q > 1$: $\sqrt{\lambda_{\max}(\Phi^\perp)}$ 部分典则相关系数

具体计算步骤如下（仅考虑 $q = 1$ 情形）

(1) 计算随机变量 y 和随机向量 \mathbf{x} 之间的决定系数

- $\begin{pmatrix} y \\ \mathbf{x} \end{pmatrix}$ 的协方差矩阵: $\Sigma = \begin{pmatrix} \Sigma_{yy} & \Sigma_{yx} \\ \Sigma_{xy} & \Sigma_{xx} \end{pmatrix}$
- $R^2 = \Sigma_{yx} \Sigma_{xx}^{-1} \Sigma_{xy} / \Sigma_{yy}$

(2) 控制 \mathbf{z} 时，计算随机变量 y 和随机向量 \mathbf{x} 之间的部分决定系数 $R_{yx \cdot z}^2$

- $\begin{pmatrix} y \\ \mathbf{x} \\ \mathbf{z} \end{pmatrix} \triangleq \begin{pmatrix} \mathbf{w} \\ \mathbf{z} \end{pmatrix}$ 的协方差矩阵: $\Sigma = \begin{pmatrix} \Sigma_{yy} & \Sigma_{yx} & \Sigma_{yz} \\ \Sigma_{xy} & \Sigma_{xx} & \Sigma_{xz} \\ \Sigma_{zy} & \Sigma_{zx} & \Sigma_{zz} \end{pmatrix} = \begin{pmatrix} \Sigma_{ww} & \Sigma_{wz} \\ \Sigma_{zw} & \Sigma_{zz} \end{pmatrix}$
- 计算 $\mathbf{w} = \begin{pmatrix} y \\ \mathbf{x} \end{pmatrix}$ 的关于 \mathbf{z} 的偏协方差矩阵 $\Sigma_{ww \cdot z} = \Sigma_{ww} - \Sigma_{wz} \Sigma_{zz}^{-1} \Sigma_{zw}$:

$$\begin{pmatrix} \Sigma_{yy \cdot z} & \Sigma_{yx \cdot z} \\ \Sigma_{xy \cdot z} & \Sigma_{xx \cdot z} \end{pmatrix} = \begin{pmatrix} \Sigma_{yy} & \Sigma_{yx} \\ \Sigma_{xy} & \Sigma_{xx} \end{pmatrix} - \begin{pmatrix} \Sigma_{yz} \\ \Sigma_{xz} \end{pmatrix} \Sigma_{zz}^{-1} (\Sigma_{zy}, \Sigma_{zx})$$
- $R_{yx \cdot z}^2 = \Sigma_{yx \cdot z} \Sigma_{xx \cdot z}^{-1} \Sigma_{xy \cdot z} / \Sigma_{yy \cdot z}$

例1. 三个变量 (y, x, z) 的相关系数矩阵:

$$\Sigma = \begin{pmatrix} 1 & \rho_{yx} & \rho_{yz} \\ \rho_{xy} & 1 & \rho_{xz} \\ \rho_{zy} & \rho_{zx} & 1 \end{pmatrix}$$

(1) y 与 (x, z) 的决定系数 :

$$R^2 = (\rho_{yx}, \rho_{yz}) \begin{pmatrix} 1 & \rho_{xz} \\ \rho_{zx} & 1 \end{pmatrix}^{-1} \begin{pmatrix} \rho_{xy} \\ \rho_{zy} \end{pmatrix} / \Sigma_{yy} = \frac{\rho_{yx}^2 + \rho_{yz}^2 - 2\rho_{yx}\rho_{yz}\rho_{xz}}{1 - \rho_{xz}^2}$$

(2) 控制 z 条件下, y 与 x 的偏决定系数:

$$\text{首先} \begin{pmatrix} \Sigma_{yy \cdot z} & \Sigma_{yx \cdot z} \\ \Sigma_{xy \cdot z} & \Sigma_{xx \cdot z} \end{pmatrix} = \begin{pmatrix} 1 & \rho_{yx} \\ \rho_{xy} & 1 \end{pmatrix} - \begin{pmatrix} \rho_{yz} \\ \rho_{xz} \end{pmatrix} (\rho_{zy}, \rho_{zx}) = \begin{pmatrix} 1 - \rho_{yz}^2 & \rho_{yx} - \rho_{yz}\rho_{xz} \\ \rho_{yx} - \rho_{yz}\rho_{xz} & 1 - \rho_{xz}^2 \end{pmatrix}$$

$$\Rightarrow R_{yx \cdot z}^2 = \Sigma_{yx \cdot z} \Sigma_{xx \cdot z}^{-1} \Sigma_{xy \cdot z} / \Sigma_{yy \cdot z} = (\rho_{yx} - \rho_{yz}\rho_{xz})^2 / (1 - \rho_{yz}^2)(1 - \rho_{xz}^2)$$

$$= (r_{yx \cdot z})^2 = \text{偏相关系数的平方。}$$

数值例子:

第二讲例3(续)中, 阅读能力 y , 身高 x , 年龄 z 的相关系数矩阵为

$$\Sigma = \begin{matrix} & \begin{matrix} y & x & z \end{matrix} \\ \begin{matrix} y \\ x \\ z \end{matrix} & \begin{pmatrix} 1 & 0.56 & 0.7 \\ 0.56 & 1 & 0.8 \\ 0.7 & 0.8 & 1 \end{pmatrix} \end{matrix}$$

$$R^2 = (0.56, 0.7) \begin{pmatrix} 1 & 0.8 \\ 0.8 & 1 \end{pmatrix}^{-1} \begin{pmatrix} 0.56 \\ 0.57 \end{pmatrix} = 0.49$$

$$\begin{pmatrix} \Sigma_{yy \bullet z} & \Sigma_{yx \bullet z} \\ \Sigma_{xy \bullet z} & \Sigma_{xx \bullet z} \end{pmatrix} = \begin{pmatrix} 1 & 0.56 \\ 0.56 & 1 \end{pmatrix} - \begin{pmatrix} 0.7 \\ 0.8 \end{pmatrix} (0.7, 0.8) = \begin{matrix} & \begin{matrix} y & x \end{matrix} \\ \begin{matrix} y \\ x \end{matrix} & \begin{pmatrix} 0.51 & 0 \\ 0 & 0.36 \end{pmatrix} \end{matrix}$$

$$\Rightarrow R_{yx \bullet z}^2 = \Sigma_{yx \bullet z} \Sigma_{xx \bullet z}^{-1} \Sigma_{xy \bullet z} / \Sigma_{yy \bullet z} = 0 = (r_{yx \bullet z})^2$$

线性回归模型

即使控制变量，相关分析也不足以推断因果关系，这是因为不相关（去相关化）不等同于独立。

线性回归模型有更强的假设，即误差与自变量独立。该条件成立时，参数才能正确地估计（无偏），有好的理论性质。

多元线性回归模型

定义：假设 $\mathbf{y}_{q \times 1}$, $\mathbf{x}_{p \times 1}$ 满足：

$$\mathbf{y}_{q \times 1} = \mathbf{a}_{q \times 1} + B_{q \times p} \mathbf{x}_{p \times 1} + \boldsymbol{\varepsilon}_{q \times 1}, \quad E(\boldsymbol{\varepsilon}) = \mathbf{0}, \quad \text{var}(\boldsymbol{\varepsilon}) = \Omega, \quad \underline{\underline{\boldsymbol{\varepsilon} \text{不可观测, 与} \mathbf{x} \text{独立}}}$$

称为多元线性回归模型。

注：对比去相关化的正交分解：

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

线性模型对误差项有更高的要求： \mathbf{y}^\perp 与 \mathbf{x} 独立。

但独立性条件在实际操作中无法执行，数据分析方法（比如最小二乘）实质上只利用了误差与自变量的不相关性。因此，从实际操作的角度看，线性模型与去相关化本质相同。

线性模型与去相关化

命题1. 多元线性回归模型的参数 \mathbf{a} , B , Ω 由 \mathbf{y}, \mathbf{x} 的均值和方差决定:

$$B = \Sigma_{yx} \Sigma_{xx}^{-1}, \quad \mathbf{a} = \boldsymbol{\mu}_y - B \boldsymbol{\mu}_x, \quad \Omega = \Sigma_{yy \cdot x}$$

注: 由命题, 线性回归模型可写成去相关化的形式:

$$\mathbf{y} - \Sigma_{yx} \Sigma_{xx}^{-1} \mathbf{x} = \boldsymbol{\varepsilon} + \boldsymbol{\mu}_y - \Sigma_{yx} \Sigma_{xx}^{-1} \boldsymbol{\mu}_x$$

差别在于 (1) 模型要求 $\mathbf{y} - \Sigma_{yx} \Sigma_{xx}^{-1} \mathbf{x}$ 与 \mathbf{x} 独立, (2) $E(\boldsymbol{\varepsilon}) = \mathbf{0}$ 导致多出一个截距项。

证明: 前面求解相关化时除了均值, 已经基本验证, 再次证明如下:

- $\boldsymbol{\varepsilon}$ 与 \mathbf{x} 独立

$$\Rightarrow 0 = \text{cov}(\boldsymbol{\varepsilon}, \mathbf{x}) = \text{cov}(\mathbf{y} - \mathbf{a} - B\mathbf{x}, \mathbf{x}) = \Sigma_{yx} - B\Sigma_{xx} \Rightarrow B = \Sigma_{yx} \Sigma_{xx}^{-1}$$

- 方程两边求均值

$$\Rightarrow \boldsymbol{\mu}_y = \mathbf{a} + B\boldsymbol{\mu}_x \Rightarrow \mathbf{a} = \boldsymbol{\mu}_y - B\boldsymbol{\mu}_x = \boldsymbol{\mu}_y - \Sigma_{yx} \Sigma_{xx}^{-1} \boldsymbol{\mu}_x$$

- 方程两边求方差

$$\Rightarrow \Sigma_{yy} = \text{var}(B\mathbf{x}) + \text{var}(\boldsymbol{\varepsilon}) = B\Sigma_{xx}B^T + \Omega = \Sigma_{yx} \Sigma_{xx}^{-1} \Sigma_{xy} + \Omega$$

$$\Rightarrow \Omega = \Sigma_{yy} - \Sigma_{yx} \Sigma_{xx}^{-1} \Sigma_{xy}$$

(一元)线性回归模型

定义: (一元)线性回归模型假设一元响应变量 y 和自变量向量 \mathbf{x} 满足方程:

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

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

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

注1: Gauss - Markov假设(1),(2)简单记为 $\varepsilon \sim (0, \sigma^2)$ 。

注2: 一般教科书上认为 \mathbf{x} 是给定的, 通常不提条件(3)。

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

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

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

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

其中 $R^2 = \frac{\text{var}(\mathbf{b}^T \mathbf{x})}{\text{var}(y)} = \Sigma_{\mathbf{yx}} \Sigma_{\mathbf{xx}}^{-1} \Sigma_{\mathbf{xy}} / \Sigma_{yy}$ 。

参数的 矩估计

所有参数可由矩估计方法得到。假设样本 (y_i, \mathbf{x}_i) 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

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

则参数 a , \mathbf{b} , σ^2 的矩估计

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

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

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

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

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

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

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) $y^\perp = a + \mathbf{b}_1^\top \mathbf{x}_1^\perp + \varepsilon$, $E(\varepsilon) = 0$, $\text{var}(\varepsilon) = \sigma^2$, 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 $R_{1y \cdot 2}^2 = \frac{\text{var}(\mathbf{b}_1^\top \mathbf{x}_1^\perp)}{\text{var}(y^\perp)} = \frac{\Sigma_{y1 \cdot 2} \Sigma_{11 \cdot 2}^{-1} \Sigma_{1y \cdot 2}}{\Sigma_{yy \cdot 2}}$.

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,

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

$\Rightarrow \mathbf{c}^\top = 0$, 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

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

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

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

(4) 部分决定系数 $R_{y1 \bullet 2}^2$ 即模型(1)的决定系数

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

(2) $\mathbf{b}_1 = \Sigma_{11 \cdot 2}^{-1} \Sigma_{1y \cdot 2}$ 的直接证明(利用分块矩阵的逆矩阵公式化):

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

命题4. 若 (y, \mathbf{x}) 满足线性模型的Gauss - Markov假设(1),(2),(3), 则
(i) $E(y | \mathbf{x}) = a + \mathbf{b}^T \mathbf{x}$ (回归函数 / 条件期望 $E(y | \mathbf{x})$ 是线性函数)
(ii) $\text{var}(y | \mathbf{x}) = \sigma^2$ (条件方差 $\text{var}(y | \mathbf{x})$ 是常数, 不依赖于 \mathbf{x})

证明: 因为 ε 与 \mathbf{x} 独立, 所以 $E(\varepsilon | \mathbf{x}) = E(\varepsilon) = 0$, 所以
 $E(y | \mathbf{x}) = E(a + \mathbf{b}^T \mathbf{x} + \varepsilon | \mathbf{x}) = a + \mathbf{b}^T \mathbf{x} + E(\varepsilon | \mathbf{x}) = a + \mathbf{b}^T \mathbf{x}$,
 $\text{var}(y | \mathbf{x}) = \text{var}(a + \mathbf{b}^T \mathbf{x} + \varepsilon | \mathbf{x}) = \text{var}(\varepsilon | \mathbf{x}) = \text{var}(\varepsilon) = \sigma^2$.

注: 条件 (i)、(ii) 可导出 (1),(2),但不能得到(3)。
有时线性模型以稍弱于 Gauss - Markov条件的 (i)、(ii) 定义
(参见下页)。

另一种 模型定 义方式

y : 响应变量, \mathbf{x} : 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: $\text{var}(y | \mathbf{x}) = \sigma^2$.

条件(i),(ii)与条件(1),(2),(3)不等价:

(1),(2),(3) \Rightarrow (i),(ii)

(i),(ii) \Rightarrow (1),(2),但不蕴含“ ε 与 \mathbf{x} 独立”。

验证: 令 $\varepsilon = y - E(y | \mathbf{x}) = y - (a + \mathbf{b}^T \mathbf{x})$, 则

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

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

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

附：关于回归函数 $E(y|\mathbf{x})$

性质1. 假设二阶矩存在, 以 \mathbf{x} 的函数 $f(\mathbf{x})$ 逼近 y 的平方误差定义为 $E(y - f(\mathbf{x}))^2$, 则 $f(\mathbf{x}) = E(y|\mathbf{x})$ 时误差最小.

性质2: 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) 令 $\varepsilon = y - E(y|\mathbf{x})$, 则 ε 与 \mathbf{x} 不相关且 $E(\varepsilon) = 0$,

我们有正交分解: $y = E(y|\mathbf{x}) + \varepsilon$

(3) Law of total variance (正交分解两边求方差):

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

注: 由 (3) 我们可定义决定系数(y 的方差中 \mathbf{x} 能解释的比例):

$$R^2 = \text{var}(E(y|\mathbf{x})) / \text{var}(y)$$