

## 第二节 一元线性回归模型

### 一、模型的建立

### 二、参数估计

### 三、回归方程的显著性检验

第十章 回归分析(2) 统计学概论(温州大学陈希镇)

回归分析就是要研究具有相关关系的变量之间的统计规律性。回归分析在工农业生产及科学研究中有着广泛的应用。在试验数据的处理、经验公式的寻找、产品的统计质量管理、市场预测、某些新标准的制订、自动控制中数学模型的建立、气象预报、地质勘探、医药卫生等许多领域中都经常需要用到回归分析。

在回归分析中，把变量分成两类，一类是因变量，常是实际问题中所关心的一些指标，常用 $y$ 表示；另一类是自变量，是影响因变量取值的一些变量，常用 $x_1, x_2, \dots, x_p$ 表示。

在回归分析中要研究的主要问题是：

1. 确定 $y$ 与 $x_1, x_2, \dots, x_p$ 之间的线性表达式，即估计表达式中的未知参数，这种表达式称为回归方程；
2. 对求得的回归方程的可信度进行检验；
3. 判断自变量 $x_i (i = 1, 2, \dots, p)$ 对 $y$ 有无影响，剔除影响不大的变量；
4. 利用所得的回归方程进行预测和控制。

第十章 回归分析(2) 统计学概论(温州大学陈希镇)

## 一、模型的建立

最简单的回归分析是一元线性回归分析。为了弄清它解决什么问题，我们先看一个例子。

例10.2.1 根据专业知识，合金钢的强度  $y(kg/mm^2)$  与钢材中碳的含量  $x(%)$  之间有着密切关系。为了冶炼出符合所要求强度的钢，常通过控制钢水中碳的含量来达到目的。为此需要了解  $y$  与  $x$  的关系。下表是合金钢的强度和碳含量这两个变量之间的12组观测数据。

第十章 回归分析(2) 统计学概论(温州大学陈希镇)

表10.2.1 碳含量 $x(%)$  与钢的强度 $y(kg/mm^2)$  的12组数据

序号	1	2	3	4	5	6	7	8	9	10	11	12
x	0.10	0.11	0.12	0.13	0.14	0.15	0.16	0.17	0.18	0.19	0.20	0.21
y	42.0	43.5	45.0	45.5	45.0	47.5	49.0	53.0	50.0	55.0	55.0	60.0

由于各种因素的影响，即使钢水中碳的含量相同，合金钢的强度也不完全相同，因而它们间的关系是一种非确定性的关系。为了探求它们之间的关系，我们先把  $(x_i, y_i)$  看成是平面直角坐标系中的一个点，画出散点图：

第十章 回归分析(2) 统计学概论(温州大学陈希镇)

由散点图可以发现，这些点散布在一直线附近，但又不全在这条直线上，因此我们可以认为变量  $y$  与变量  $x$  之间近似存在线性关系：

$$y = \beta_0 + \beta_1 x$$

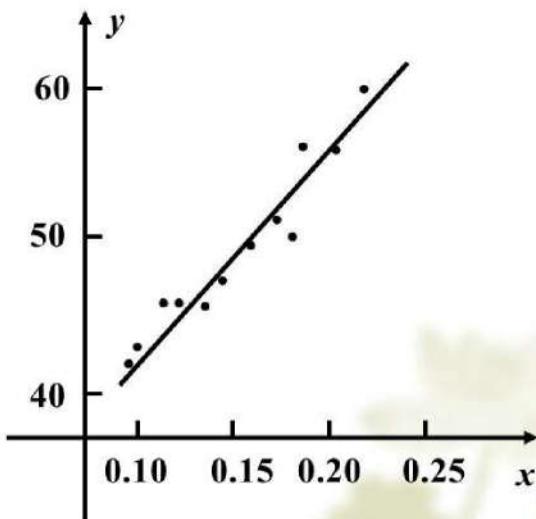


图 10.2.1 散点图

## 第十章 回归分析(2) 统计学概论(温州大学陈希镇)

观察所画的散点图上点的分布规律，如果发现这些点散布在一直线附近，但又不全在一条直线上，那么我们可以认为变量  $y$  与变量  $x$  之间近似存在线性关系。这种关系由两部分组成，一部分是由于  $x$  的变化引起  $y$  的变化部分，记为：

$\beta_0 + \beta_1 x$ ，另一部分是由随机因素引起的误差，记为： $\varepsilon$ ，于是有  $y = \beta_0 + \beta_1 x + \varepsilon$ 。现有数据对  $(x_i, y_i)$ ,  $i = 1, 2, \dots, n$ ，其中  $y_1, y_2, \dots, y_n$  相互独立，而诸  $x_i$  是一般变量，其值可以精确测量或严格控制， $\beta_0, \beta_1$  为未知参数， $\varepsilon_i$  是不可观测的随机误差。又设  $E(\varepsilon) = 0$ ,  $D(\varepsilon) = \sigma^2$ ，从而可得一元线性回归的数学模型如下：

$$\begin{cases} y_i = \beta_0 + \beta_1 x_i + \varepsilon_i, & i = 1, 2, \dots, n \\ E(\varepsilon_i) = 0, \quad D(\varepsilon_i) = \sigma^2, & i = 1, 2, \dots, n \end{cases} \quad (10.2.1)$$

## 第十章 回归分析(2) 统计学概论(温州大学陈希镇)



若还有  $\varepsilon \sim N(0, \sigma^2)$ , 即有  $y \sim N(\beta_0 + \beta_1 x, \sigma^2)$ ,  
则模型加强为:

$$\begin{cases} y_i = \beta_0 + \beta_1 x_i + \varepsilon_i, & i = 1, 2, \dots, n \\ \varepsilon_1, \varepsilon_2, \dots, \varepsilon_n, & i.i.d. \sim N(0, \sigma^2) \end{cases} \quad (10.2.2)$$

称  $E(y) = \beta_0 + \beta_1 x$  为变量  $y$  关于变量  $x$  的回归函数。它在平均意义上表明  $y$  与  $x$  之间存在一种统计规律性。



在这里要研究的问题是:

(1) 如何根据样本  $(x_i, y_i), i = 1, 2, \dots, n$  求出  $\beta_0, \beta_1$  的点估计  $\hat{\beta}_0, \hat{\beta}_1$ , 则称  $\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x$  为  $y$  关于  $x$  的一元线性回归方程, 这表明  $\hat{y}$  是  $x$  的函数, 有时也记  $\hat{y}$  为  $\hat{y}(x)$ , 称为拟合值或预测值。

(2) 如何检验回归方程的可信度?

## 二. 参数 $\beta_0$ , $\beta_1$ 的最小二乘估计

要求模型 (9.2.1) 中参数  $\beta_0$ ,  $\beta_1$  的估计, 就是求这样的估计  $\hat{\beta}_0$ ,  $\hat{\beta}_1$ , 它使观测值  $y$  与拟合值  $\hat{y}$  之间的偏差平方和达到最小。记:

$$Q(\beta_0, \beta_1) = \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i)^2 \quad (10.2.3)$$

则所求的  $\hat{\beta}_0$ ,  $\hat{\beta}_1$  应满足下列要求:

$$Q(\hat{\beta}_0, \hat{\beta}_1) = \min_{\beta_0, \beta_1} Q(\beta_0, \beta_1) \quad (10.2.4)$$

满足 (10.2.4) 的  $\hat{\beta}_0$ ,  $\hat{\beta}_1$  称为  $\beta_0$ ,  $\beta_1$  的最小二乘估计, 简记为  $LSE$

对  $Q(\beta_0, \beta_1)$  求关于  $\beta_0$ ,  $\beta_1$  的偏导数并令其等于零, 得

$$\begin{cases} \frac{\partial Q}{\partial \beta_0} \triangleq 0 \\ \frac{\partial Q}{\partial \beta_1} \triangleq 0 \end{cases}$$

整理得正规方程组:

$$\begin{cases} \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i) = 0 \\ \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_i) x_i = 0 \end{cases}$$

于是得

$$\begin{cases} \bar{y} = \beta_0 + \beta_1 \bar{x} \\ \bar{x}\beta_0 + \frac{1}{n} \sum_{i=1}^n x_i^2 \beta_1 = \frac{1}{n} \sum_{i=1}^n x_i y_i \end{cases}$$

整理得:

$$\begin{cases} \hat{\beta}_1 = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} \triangleq l_{xy} \\ \hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x} \end{cases}$$

其中  $l_{xy} = \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \sum_{i=1}^n x_i y_i - n \bar{x} \cdot \bar{y}$ ,

$$l_{xx} = \sum_{i=1}^n (x_i - \bar{x})^2 = \sum_{i=1}^n x_i^2 - n \bar{x}^2$$

第十章 回归分析(2) 统计学概论(温州大学陈希镇)

由此可知, 要求  $\beta_0$ ,  $\beta_1$  的最小二乘估计, 只要先计算

$$\sum_{i=1}^n x_i, \sum_{i=1}^n y_i, \sum_{i=1}^n x_i^2, \sum_{i=1}^n x_i y_i, \sum_{i=1}^n y_i^2$$

然后可算出  $\bar{x}$ ,  $\bar{y}$ ,  $l_{xy}$ ,  $l_{xx}$ , 从而可以算出  $\hat{\beta}_0$ ,  $\hat{\beta}_1$

$$\hat{\beta}_1 = \frac{l_{xy}}{l_{xx}} = \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \cdot \bar{y}}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}$$

$$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}$$

第十章 回归分析(2) 统计学概论(温州大学陈希镇)

下面求例10.2.1中合金强度关于碳含量的一元线性回归方程组。

由表10.2.1 可得  $\sum_{i=1}^n x_i = 1.90$ ,  $\sum_{i=1}^n y_i = 590.5$ ,

$$\sum_{i=1}^n x_i^2 = 0.3194, \quad \sum_{i=1}^n x_i y_i = 95.9250,$$

据此得  $\bar{x} = 0.1583$ ,  $\bar{y} = 49.2083$ ,

$$l_{xx} = 0.0186, \quad l_{xy} = 2.4292,$$

于是求得估计值如下:  $\hat{\beta}_1 = l_{xy} / l_{xx} = 130.6022$ ,

$$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x} = 28.5340,$$

从而求得一元线性回归方程组为:

$$\hat{y} = 28.5340 + 130.6022x \quad (10.2.6)$$

为了后面讨论的需要, 下面研究最小二乘估计的性质

**性质1** 在模型 (10.2.1) 下, 有  $E(\hat{\beta}_0) = \beta_0$ ,  $E(\hat{\beta}_1) = \beta_1$

**性质2** 在模型 (10.2.1) 下, 有  $D(\hat{\beta}_1) = \sigma^2 / l_{xx}$ ,

$$D(\hat{\beta}_0) = \left( \frac{1}{n} + \frac{\bar{x}^2}{l_{xx}} \right) \sigma^2, \quad Cov(\hat{\beta}_0, \hat{\beta}_1) = -\frac{\bar{x}}{l_{xx}} \sigma^2$$

**性质3** 在模型 (10.2.2) 下,  $\hat{\beta}_0 \sim N(\beta_0, (\frac{1}{n} + \frac{\bar{x}^2}{l_{xx}}) \sigma^2)$ ,

$\hat{\beta}_1 \sim N(\beta_1, \frac{\sigma^2}{l_{xx}})$ , 且  $\bar{y}$  与  $\hat{\beta}_1$  相互独立。

**性质4** 在模型 (10.2.2) 下,  $E(\hat{y}) = \beta_0 + \beta_1 x = E(y)$ ,

$$D(\hat{y}) = \left[ \frac{1}{n} + \frac{(x - \bar{x})^2}{l_{xx}} \right] \sigma^2, \quad \hat{y} \sim N(\beta_0 + \beta_1 x, \left[ \frac{1}{n} + \frac{(x - \bar{x})^2}{l_{xx}} \right] \sigma^2)$$

### 三、回归方程的显著性检验

由一元线性回归方程系数的最小二乘估计公式可知，不管  $y$  与  $x$  之间是否有线性关系，只要给出  $n$  对数据

$$(x_i, y_i), i = 1, 2, \dots, n,$$

我们总能求出  $\hat{\beta}_0$ ,  $\hat{\beta}_1$ , 从而得到回归方程  $\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x$ 。

**问题：**这样得到的方程是否有实际意义？

在一元线性回归中， $\beta_1$  反映  $E(y)$  随  $x$  变化程度的大小。

若  $\beta_1 \neq 0$ , 说明  $E(y)$  随  $x$  的变化而变化，这时所给的方程才有实际意义。

若  $\beta_1 = 0$ , 说明  $E(y)$  不随  $x$  的变化而变化，这时所给的方程没有实际意义。因此对回归方程要作显著性检验是：

$$H_0: \beta_1 = 0 \leftrightarrow H_1: \beta_1 \neq 0$$

引起随机变量观测值  $y_1, y_2, \dots, y_p$  变化的原因有：

其一是由于  $H_0$  不真，从而  $x$  的变化引起  $E(y)$  的变化；

其二是由于其它因素造成的随机误差所致。

为了分清究竟是什么原因引起随机变量观测值变化，因此需要把引起波动的上述两个原因从总的波动中分离出来。



考虑总偏差平方和  $SS_T = \sum_{i=1}^n (y_i - \bar{y})^2 = l_{yy}$ ,

把总偏差平方和分解:

$$\begin{aligned} SS_T &= \sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n (y_i - \hat{y}_i + \hat{y}_i - \bar{y})^2 \\ &= \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 + 2 \sum_{i=1}^n (y_i - \hat{y}_i)(\hat{y}_i - \bar{y}) \\ &= SS_e + SS_R \end{aligned}$$

其中

$$SS_R = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 \quad \text{称为回归平方和}$$

$$SS_e = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad \text{称为残差平方和}$$

下面求  $SS_R$ ,  $SS_e$  的期望。

## 第十章 回归分析(2) 统计学概论(温州大学陈希镇)



(1) 利用  $\hat{\beta}_1 = l_{xy} / l_{xx}$ ,  $\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}$ ,

$$SS_R = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 = \hat{\beta}_1^2 \sum_{i=1}^n (x_i - \bar{x})^2 = \hat{\beta}_1^2 l_{xx} = l_{xy}^2 / l_{xx}$$

由性质2知

$$E(SS_R) = E(\hat{\beta}_1^2 l_{xx}) = \{D\hat{\beta}_1 + [E\hat{\beta}_1]^2\}l_{xx} = \sigma^2 + \beta_1^2 l_{xx}$$

上式表明, 若  $\beta_1 = 0$ ,  $E(SS_R) = \sigma^2$ ,

这时从平均意义上说,  $SS_R$  仅反映了随机误差引起差异;

$$\beta_1 \neq 0, \quad E(SS_R) = \sigma^2 + \beta_1^2 l_{xx},$$

这时  $SS_R$  还反映  $E(y)$  随  $x$  变化所引起的差异。因此称之为回归平方和。

## 第十章 回归分析(2) 统计学概论(温州大学陈希镇)

当  $\beta_1 = 0$  时, 由性质 3,  $\hat{\beta}_1 \sim N(\beta_1, \sigma^2 / l_{xx})$ ,

所以  $SS_R / \sigma^2 = \hat{\beta}_1^2 l_{xx} / \sigma^2 = [\hat{\beta}_1 / (\sigma / \sqrt{l_{xx}})]^2 \sim \chi^2(1)$

其自由度  $f_e = 1$ 。

由于  $y_1, y_2, \dots, y_n$  iid  $\sim N(\beta_0, \sigma^2)$ ,

$$SS_T / \sigma^2 = \sum (y_i - \bar{y})^2 / \sigma^2 \sim \chi^2(n-1)$$

其自由度为  $f_T = n-1$ 。

$$\text{又 } SS_e = SS_T - SS_R = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i)^2$$

其自由度为  $f_e = n-2$ 。

$$E(SS_e) = E(SS_T) - E(SS_R) = (n-1)\sigma^2 - \sigma^2 = (n-2)\sigma^2$$

由 Cochran 定理知,  $SS_e / \sigma^2 \sim \chi^2(n-2)$ ,

第十章 回归分析(2) 统计学概论(温州大学陈希镇)

且  $SS_e$  与  $SS_R$  相互独立。因此当  $\beta_1 = 0$ ,

$$E(SS_R) = \sigma^2, \quad E\left(\frac{SS_e}{n-2}\right) = \sigma^2,$$

$SS_e$  只反映随机误差所引起的差异, 故称为残差平方和。当

$$\beta_1 \neq 0, \quad E(SS_R) > \sigma^2,$$

取检验统计量为:  $F = \frac{SS_R}{SS_e / (n-2)} \sim F(1, n-2)$

对给定的  $\alpha > 0$ , 查表的上  $\alpha$  分位数  $C = F_{1-\alpha}(1, n-2)$ ,

拒绝域是:  $D = \{F_{\text{值}} > F_{1-\alpha}(1, n-2)\}$

第十章 回归分析(2) 统计学概论(温州大学陈希镇)

对例10.2.1中的回归方程  $\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x$ , 作显著性检验, 得如下的方差分析表。

表10.2.2 方差分析表

来源	平方和	自由度	均方和 MS	F比值
回归	$SS_R = l_{xy}^2 / l_{xx}$ = 317.2589	$f_R = 1$	$MS_R = SS_R / f_R$ = 317.2589	$F = \frac{SS_R / f_R}{SS_e / f_E}$ = 176.55
残差	$SS_e = SS_T - SS_R$ = 17.9703	$f_e = 10$	$MS_e = SS_e / f_e$ = 1.7970	
总和	$SS_T = 335.2292$	$f_T = 11$	$F_{0.05}(1, 10)$ = 4.96 < 176.55	

这表明在  $\alpha = 0.05$  的水平上, 方程 (10.2.6) 是有意义的。