

# 第1章

## 理论介绍

本书涉及的理论基础包括：区间规划模型、SLP 模型、模糊综合评价模型、分数阶理论以及数据挖掘等理论方法，将在本章进行详细的介绍及分析，为本书的理论研究奠定基础。

### 1.1 线性回归模型

回归分析是考察变量之间统计联系的一种重要方法，它在数学建模、自然科学和社会科学等许多领域中都有极其广泛的作用。本节主要讨论一个随机变量或多个随机变量之间的关系。回归(regression)一词是英国著名人类学家和气象学家 Francis Galton(1822—1911 年)于 1885 年引入的。在“身高遗传中的平庸回归”的论文中，Galton 阐述了他的重大发现：虽然高个子的先代会有高个子的后代，但子代的身高并不像其父代，而是趋向于比他们的父代更加平均，就是说如果父亲身材高大，则子代的身材要比父代矮小一些；如果父亲身材矮小，则子代的身材要比父代高大一些。因此，他用回归一词来描述子代身高与父代身高的这种关系。而后，他的朋友、英国著名统计学家 K. Pearson 等人搜集了上千个家庭成员的身高数据，分析出儿子的身高  $y$  与父亲的身高  $x$  大致可归结为以下关系：

$$y = 0.516x + 33.73 \quad (\text{单位为英寸})$$

此式进一步证实了 Galton 的“回归定律”。这就是回归一词最初在遗传学上的含义。

#### 1.1.1 回归的概念

变量之间的关系大致可分为两类：一类是确定性的关系，如我们熟知的函

数关系；另一类是非确定性的关系. 对于某些非确定性的关系, 如随机变量  $Y$  与变量  $x$  (它可能是多维向量) 之间的关系, 当自变量  $x$  确定之后, 因变量  $Y$  的值并不随着确定, 而是按一定的统计规律 (即随机变量  $Y$  的分布) 取值. 这时我们将它们之间的关系表示为

$$Y = f(x) + \epsilon$$

其中,  $f(x)$  是一个确定的函数, 称为回归函数,  $\epsilon$  为随机项, 且  $\epsilon \sim N(0, \delta^2)$ .

回归分析的任务之一是确定回归函数  $f(x)$ . 当  $f(x)$  是一元线性函数时, 称为一元线性回归; 当  $f(x)$  是多元线性函数时, 称为多元线性回归; 当  $f(x)$  是非线性函数时, 称为非线性回归.

### 1.1.2 一元线性回归

#### 1. 一元线性回归的数学模型

假定只研究  $x$  与  $y$  的关系, 可以有如下结构式:

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

式中,  $\beta_0$  和  $\beta_1$  是未知常数,  $\epsilon$  表示其他随机因素对  $y$  获得率的影响, 它服从  $N(0, \sigma^2)$  分布.

取定一组不完全相同的值  $x_1, x_2, \dots, x_n$ , 作独立试验得到  $n$  对观察结果  $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ , 其中  $y_i$  是  $x = x_i$  处对随机变量  $y$  观察的结果. 将数据点  $(x_i, y_i) (i=1, 2, \dots, n)$  代入, 则有

$$y_i = \beta_0 + \beta_1 x_i + \epsilon_i, \quad i = 1, 2, \dots, n$$

并且假定  $\epsilon_i \sim N(0, \sigma^2)$ .

回归分析的首要任务是通过观察结果来确定回归系数  $\beta_0, \beta_1$  的估计  $\hat{\beta}_0, \hat{\beta}_1$ , 以下用最小二乘法确定回归直线方程:

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

因为我们要确定一条直线, 也就是要确定  $\beta_0, \beta_1$  的估计值, 使回归直线与所有数据点都比较“接近”. 为了刻画这种“接近”程度, 我们引进残差的概念, 所谓残差是指观察值  $y_i$  与回归值  $\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i$  的偏差  $y_i - \hat{y}_i$ , 很自然地可以用绝对残差和  $\sum_{i=1}^n |y_i - \hat{y}_i|$  来度量观察值与回归直线的接近程度. 绝对残差和越小, 回归直线就与所有数据点越接近. 但为计算方便, 一般用残差平方和:

$$Q(\beta_0, \beta_1) = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n [y_i - (\beta_0 + \beta_1 x_i)]^2$$

来描述所有观察值与回归直线的偏离程度.

所谓最小二乘估计,就是使残差平方和  $Q$  达到最小值的  $\beta_0, \beta_1$  作为回归系数的估计.

$$\text{令 } \frac{\partial Q}{\partial \beta_0} = 0, \frac{\partial Q}{\partial \beta_1} = 0, \text{ 得}$$

$$\hat{\beta}_1 = \frac{S_{xy}}{S_{xx}}, \quad \hat{\beta}_0 = \bar{y} - \beta_1 \bar{x}$$

其中,

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i, \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i, S_{xx} = \sum_{i=1}^n (x_i - \bar{x})^2, S_{xy} = \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}).$$

## 2. 一元线性回归的显著性检验

从前面求回归方程的过程来看,对任意样本观察值  $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$  做出的散点图,即使一看就知道这些点不可能近似在一条直线的附近,即  $y$  与  $x$  不存在线性关系,但是,若用最小二乘法仍然可求得  $y$  对  $x$  的线性回归方程与  $y = \beta_0 + \beta_1 x$ , 这样求得的方程是没有意义的. 所以,在求  $y$  对  $x$  的线性回归方程之前,必须判断  $y$  与  $x$  的关系是否满足一元线性回归模型.

在处理具体问题时,判断  $y$  与  $x$  的关系是否满足一元线性回归模型,专业知识是重要的,在数学上,做出散点图是一种粗略的判断. 下面介绍根据样本观察值  $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$  进行统计检验的一种做法.

由  $y = \beta_0 + \beta_1 x + \varepsilon$  可知,当  $|\beta_1|$  越大,  $y$  随  $x$  的变化而变化的趋势就越明显; 当  $|\beta_1|$  越小,  $y$  随  $x$  的变化而变化的趋势就不明显,特别当  $\beta_1 = 0$  时,就认定  $y$  与  $x$  之间不存在线性相关关系. 这样,判断  $y$  与  $x$  是否满足一元线性回归模型就转化为在显著性水平  $\alpha$  下,检验假设:

$$H_0: \beta_1 = 0, \quad H_1: \beta_1 \neq 0$$

$$\text{记 } S_{yy} = \sum_{i=1}^n (y_i - \bar{y})^2, S_{xy} = \sum_{i,j=1}^n (x_i - \bar{x})(y_i - \bar{y}), U = \sum_{i=1}^n (\beta_0 + \beta_1 x - \bar{y})^2 =$$

$$\frac{S_{xy}^2}{S_{xx}} \text{ (称为回归平方和, } U + Q = S_{yy} \text{)}.$$

选取检验统计量:

$$F = \frac{U}{Q/(n-2)}$$

在  $H_0$  成立的条件下,  $F \sim F(1, n-2)$ , 得到拒绝域:

$$W = \left\{ F = \frac{U}{Q/(n-2)} \geq F_\alpha(1, n-2) \right\}$$

如果  $F > F_\alpha$ , 则否定  $H_0$ , 即变量  $y$  与  $x$  之间存在线性相关关系; 否则, 接受  $H_0$ , 即变量  $y$  与  $x$  之间不存在线性相关关系. 此时可能有以下几种情况:

(1)  $y$  对  $x$  没有显著影响, 此时应该丢掉自变量  $x$ .

(2)  $y$  对  $x$  有显著影响, 但这种情况不能用线性关系来表示, 应该做非线性回归.

(3) 除  $x$  外还有其他不可忽略的变量对  $y$  也有显著影响, 从而削弱了  $x$  对  $y$  的影响, 此时对该问题的专业知识的了解往往起着重要作用.

### 3. 利用一元线性回归进行预测与控制

如何根据样本提供的信息来预测当变量  $x = x_0$  时随机变量  $Y_0$  的值? 一个自然的想法是: 用预测量  $y_0 = \beta_0 + \beta_1 x_0$  来代替, 但是它与真值  $Y_0$  的差值是多少呢? 预测量的优劣取决于  $|y_0 - Y_0|$  的大小, 记为

$$d^2 = 1 + \frac{1}{n} + \frac{(x_0 - \bar{x})^2}{S_{xx}}, \quad \hat{\delta}^2 = \frac{Q}{n-2}$$

可以证明, 当  $Y_0$  与  $Y_1, Y_2, \dots, Y_n$  相互独立时,  $\frac{y_0 - Y_0}{d\hat{\delta}} \sim t(n-2)$ . 这样在显著性水平  $\alpha$  下可得到  $Y_0$  的预测区间:

$$[y_0 - t_\alpha(n-2)d\hat{\delta}, y_0 + t_\alpha(n-2)d\hat{\delta}]$$

当  $n$  较大时, 预测区间的上下限近似取做  $y_0 \pm 1.96\hat{\delta}$  (可信度为 95%) 或  $y_0 \pm 2.58\hat{\delta}$  (可信度为 99%).

控制是预测的反问题, 即若要随机变量  $Y$  落在指定的区间  $(y_L, y_U)$  内, 变量  $x$  应控制在什么区间内? 从方程

$$\begin{cases} y_L = \beta_0 + \beta_1 x_L - 1.96\hat{\delta}, \\ y_U = \beta_0 + \beta_1 x_U - 1.96\hat{\delta} \end{cases}$$

中解出  $x_L$  和  $x_U$ , 则当  $\beta_1 > 0$  时, 控制区间为  $(x_L, x_U)$ .

## 1.1.3 多元线性回归

在许多数学建模实际问题中, 还会遇到一个随机变量与一组变量的相关关系问题, 这要用到多元回归分析的方法来解决.

### 1. 多元线性回归的数学模型

设随机变量  $Y$  与  $m$  个变量  $x_1, x_2, \dots, x_m$  有关系

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_m x_m + \epsilon$$

其中,  $\epsilon$  为随机项, 且  $\epsilon_i \sim N(0, \sigma^2)$ . 记:

$$Y = \begin{Bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{Bmatrix}, \quad X = \begin{Bmatrix} 1 & x_{11} & \cdots & x_{1m} \\ 1 & x_{21} & \cdots & x_{2m} \\ \vdots & \vdots & & \vdots \\ 1 & x_{n1} & \cdots & x_{nm} \end{Bmatrix}_{n \times (m+1)}, \quad \epsilon = \begin{Bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{Bmatrix}, \quad \beta = \begin{Bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_m \end{Bmatrix}$$

则随机变量  $Y$  与变量  $X$  的关系可化为  $Y = X\beta + \epsilon$  与一元线性回归情况类似, 求回归系数  $\beta_0, \beta_1, \cdots, \beta_m$  的最小二乘估计. 作残差平方和:

$$Q = \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_{i1} - \cdots - \beta_m x_{im})^2$$

求  $Q$  分别关于  $\beta_0, \beta_1, \cdots, \beta_m$  的一阶偏导数, 并令它们等于零, 得

$$\beta = \begin{Bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_m \end{Bmatrix} = (X^T X)^{-1} X^T Y$$

## 2. 多元线性回归的显著性检验

与一元回归情况类似, 首先建立带检验假设:

$$H_0: \beta_1 = \beta_2 = \cdots = \beta_m = 0$$

若能通过那个检验拒绝  $H_0$ , 则  $Y$  与  $m$  个变量  $x_1, x_2, \cdots, x_m$  之间存在线性相关关系.

$$\text{记 } \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i, \quad S_{yy} = \sum_{i=1}^n (y_i - \bar{y})^2, \quad U = S_{yy} - Q.$$

选取检验统计量:

$$F = \frac{U/m}{Q/(n-m-1)}$$

在  $H_0$  成立的条件下,  $F \sim F(m-1, n-m-1)$ . 得到拒绝域:

$$W = \left\{ F = \frac{U/m}{Q/(n-m-1)} \geq F_\alpha(m-1, n-m-1) \right\}$$

如果  $F > F_\alpha$ , 则否定  $H_0$ , 即  $Y$  与  $m$  个变量  $x_1, x_2, \cdots, x_m$  之间存在线性相关关系; 否则, 接受  $H_0$ , 即  $Y$  与  $m$  个变量  $x_1, x_2, \cdots, x_m$  之间不存在线性相关关系.

在多元线性回归模型中, 拒绝假设  $H_0$ , 即回归方程显著. 然而变量  $x_1, x_2, \cdots, x_m$  对  $Y$  的影响并不都是十分重要的, 人们还关心  $Y$  对  $x_1, x_2, \cdots, x_m$  的回归中哪些因素更重要些, 哪些因素不重要. 要剔除不重要的, 需要采用偏  $F$  检验

法,即检验假设:

$$H_k: \beta_k = 0, \quad k = 1, 2, \dots, m$$

通常选取统计量:

$$F_\alpha = \frac{\beta_k^2 / a_{kk}}{Q / (n - m - 1)}$$

其中,  $a_{kk}$  是矩阵  $(\mathbf{X}^T \mathbf{X})^{-1}$  的主对角线上的第  $k+1$  个元素.

在  $H_k$  成立的条件下,  $F_k \sim F(1, n - m - 1)$ . 得到拒绝域:

$$W = \left\{ F_k = \frac{\beta_k^2 / a_{kk}}{Q / (n - m - 1)} \geq F_\alpha(1, n - m - 1) \right\}$$

如果  $F_k > F_\alpha$ , 拒绝  $H_k$ , 即  $\mathbf{x}_k$  对  $\mathbf{Y}$  的影响显著; 否则, 接受  $H_k$ , 即  $\mathbf{x}_k$  对  $\mathbf{Y}$  的影响不显著.

### 3. 预测问题

如何根据样本提供的信息来预测当变量  $(x_1, x_2, \dots, x_m) = (x_{01}, x_{02}, \dots, x_{0m})$  时随机变量  $\mathbf{Y}_0$  的值? 一个自然的想法是用预测量:

$$\mathbf{y}_0 = \beta_0 + \beta_1 \mathbf{x}_{10} + \beta_2 \mathbf{x}_{20} + \dots + \beta_m \mathbf{x}_{m0}$$

来替代. 预测量  $\mathbf{y}_0$  的优劣取决于  $|\mathbf{y}_0 - \mathbf{Y}_0|$  的大小. 记:

$$\bar{x}_j = \frac{1}{n} \sum_{i=1}^n x_{ij}, \quad l_{ij} = \sum_{k=1}^n (x_{ki} - \bar{x}_i)(x_{kj} - \bar{x}_j), \quad i, j = 1, 2, \dots, m$$

$$\mathbf{L} = \begin{Bmatrix} l_{11} & \dots & l_{1m} \\ \vdots & & \vdots \\ l_{m1} & \dots & l_{mm} \end{Bmatrix}, \quad \mathbf{L}^{-1} = \begin{Bmatrix} l'_{11} & \dots & l'_{1m} \\ \vdots & & \vdots \\ l'_{m1} & \dots & l'_{mm} \end{Bmatrix}$$

$$d^2 = 1 + \frac{1}{n} + \sum_{i=1}^m \sum_{j=1}^m l'_{ij} (x_{0i} - \bar{x}_i)(x_{0j} - \bar{x}_j), \quad \hat{\delta}^2 = \frac{Q}{n - m - 1}$$

可以证明当  $\mathbf{Y}_0$  与  $\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_n$  相互独立时,  $\frac{\mathbf{y}_0 - \mathbf{Y}_0}{d \hat{\delta}} \sim t(n - m - 1)$ . 这样在

显著性水平  $\alpha$  下可得到  $\mathbf{Y}_0$  的预测区间:

$$[\mathbf{y}_0 - t_\alpha(n - m - 1)d\hat{\delta}, \mathbf{y}_0 + t_\alpha(n - m - 1)d\hat{\delta}]$$

上面介绍了一元回归方程和多元回归方程的理论基础, 下面引入与线性模型有关的  $R$  函数.

适应于多元线性模型的基本函数是  $\text{lm}()$ , 其形式为

```
lm(formula, data, subset, weights, na.action, method = 'qr', model = TRUE,
x = FALSE, y = FALSE, qr = TRUE, singular.ok = TRUE, contrasts = NULL, offset, ...)
```

其中 formula 为模型公式; data 为数据框; subset 为可选择向量, 表示观察值的

子集；weights 为可选择向量，数据拟合的权重；返回值为线性模型结果的对象，存放在 fitted.model 中。例如：

```
fm2 <- lm(y ~ x1 + x2, data = production)
```

适用于  $y$  关于  $x_1, x_2$  的多元回归模型（隐含着截距项）。

lm()函数的返回值称为拟合结果的对象，本质上是一个具有类属性值 lm 的列表 model, coefficients, residuals 等成员。lm()的结果非常简单，为了获得更多的信息，可以使用对 lm()类对象有特殊操作的通用函数，这些函数包括：

```
addl coef effects kappa predict residuals
alias deviance family labels print step
anova drop1 formula plot proj summary
```

下面简单地介绍函数的使用方法。

(1) anova()函数。其使用格式为

```
anova(object, ...)
```

其中 object 是由 lm 或 glm 得到的对象，其返回值是模型的方差分析表。

(2) coefficients()函数简写形式为 coef()，其使用格式为

```
coefficients(object, ...)
coef(object, ...)
```

其中 object 是由模型构成的对象，其返回值是模型的系数。

(3) deviance()函数，其使用格式为

```
deviance(object, ...)
```

其中 object 是由模型构成的对象，其返回值是模型的残差平方和。

(4) formula()函数。其使用格式为

```
formula(object, ...)
```

其中 object 是由模型构成的对象，其返回值是模型公式。

(5) plot()函数，其使用格式为

```
plot(object, ...)
```

其中 object 是由 lm 构成的对象，绘制模型诊断的几种图形，显示残差、拟合值和一些诊断情况。

(6) predict()函数，其使用格式为

```
predict(object, newdata = data.frame)
```

其中 object 是由 lm 构成的对象. newdata 是预测点的数据, 它由数据框形式输入, 其返回值是预测值和预测区间.

(7) print() 函数, 其使用格式为

```
print(object, ...)
```

其中 object 是由模型构成的对象, 其返回值是显示模型拟合的结果, 一般不用 print() 而直接用键入对象的名称来显示.

(8) residuals() 函数, 其使用格式为

```
residuals (object, type = c(" working", " response", " deviance", " pearson",
"partial"),
```

其中 object 是由 lm 或 aov 构成的对象. type 是返回值的类型, 其返回值是模型的残差, 简单的命令形式为 resid(object).

(9) step() 函数, 其使用格式为

```
step(object, ...)
```

其中 object 是由 lm 或 glm 构成的对象, 其返回值是逐步回归, 根据 AIC (Akaike's Information Criterion) 的最小值选择模型.

(10) summary() 函数, 其使用格式为

```
summary(object, ...)
```

其中 object 是由 lm 构成的对象, 其返回值是显示较为详细的模型拟合结果.

**例 1.1** 根据经验, 在人的身高相等的情况下, 血压的收缩压  $Y$  与体重(千克)、年龄(岁数)有关, 现收集了 13 个男子的数据, 见表 1.1. 试建立  $Y$  关于  $X_1$ ,  $X_2$  的线性回归方程.

表 1.1 数据表

序号	$X_1$	$X_2$	$Y$	序号	$X_1$	$X_2$	$Y$
1	76.0	50	120	8	79.0	50	125
2	91.5	20	141	9	85.0	40	132
3	85.5	20	124	10	76.5	40	123
4	82.5	30	126	11	82.0	40	132
5	79.0	30	117	12	95.0	40	155
6	80.5	50	125	13	92.5	20	147
7	74.5	60	123				

解 R 软件中的 `lm()` 同样可以求出回归系数, 并作相应的检验.

下面是 R 软件的计算过程:

```
> blood <- data.frame(
  X1 = c(76.0, 91.5, 85.5, 82.5, 79.0, 80.5, 74.5, 79.0, 85.0, 76.5, 82.0,
  95.0, 92.5),
  X2 = c(50, 20, 20, 30, 30, 50, 60, 50, 40, 55, 40, 40, 20),
  Y = c(120, 141, 124, 126, 117, 125, 123, 125, 132, 123, 132, 155, 147)
)
> lm.sol <- lm(Y ~ X1 + X2, data = blood)
> summary(lm.sol)
Call:
lm(formula = Y ~ X1 + X2, data = blood)
Residuals:
    Min       1Q   Median       3Q      Max
-4.0404 -1.0183  0.4640  0.6908  4.3274
Coefficients:
            Estimate Std. Error t value Pr(> |t|)
(Intercept) -62.96336   16.99976   -3.704 0.004083 **
X1             2.13656    0.17534   12.185 2.53e-07 ***
X2             0.40022    0.08321    4.810 0.000713 ***
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
Residual standard error: 2.854 on 10 degrees of freedom
Multiple R-Squared: 0.9461, Adjusted R-squared: 0.9354
F-statistic: 87.84 on 2 and 10 DF, p-value: 4.531e-07
```

从计算结果可以得到, 回归系数与回归方程的检验都是显著的, 因此, 回归方程为

$$\hat{Y} = -62.96 + 2.136X_1 + 0.4002X_2$$

```
> source("beta.int.R")
> beta.int(lm.sol)
            Estimate           Left           Right
(Intercept) -62.9633591 -100.8411862 -25.0855320
x1            2.1365581   1.7458709   2.5272454
x2            0.4002162   0.2148077   0.5856246
```

其中 R 程序 `beta.int.R` 描述的是参数向量  $\beta$  的置信水平为  $1 - \alpha$  的区间估计程序:

```
beta.int <- function(fm, alpha = 0.05){
```

```

A <- summary(fm) $ coefficients
df <- fm $ df.residual
left <- A[, i] - A[, 2] * qt(1 - alpha/2, df)
right <- A[, 1] + A[, 2] * qt(1 - alpha/2, df)
rowname <- dimnames(A)[ [1]]
colname <- c("Estimate", "Left", "Right")
matrix(c(A[, 1], left, right), ncol = 3, dimnames = list(rowname,
colname))
}

```

其中 `summary` 是提取模型信息, 返回值为一个列表, 其中 `$ coefficients` 是由回归系数、标准差、 $t$  值和  $P$  值构成的矩阵, 若 `fm` 是由 `lm` 计算得到回归模型, 其中 `$ df.residual` 为模型的自由度。

### 1.1.4 曲线回归模型

在许多数学建模实际问题中, 一个随机变量与另一个随机变量的关系不是线性关系, 而是某种曲线关系。那么如何确定回归方程呢? 常用的有 3 种方法, 即: 化为一元线性回归、多项式回归和分段回归。

#### 1. 化为一元线性回归

在某些非线性回归方程中, 为了确定其中的未知参数, 一般将非线性回归方程转化为线性回归方程, 通过线性回归方程的参数估计将非线性回归方程的参数估计出来。表 1.2 列出了常用的可线性化回归方程 ( $a > 0$ )。

表 1.2 常用的可线性化回归方程

曲线方程	变换公式	变换后的线性方程
$1/y = a + b/x$	$u = 1/x, v = 1/y$	$v = a + bu$
$y = ax^b$	$u = \ln x, v = \ln y$	$v = c + bu (c = \ln a)$
$y = a + b \ln x$	$u = \ln x, v = y$	$v = a + bu$
$y = ae^{bx}$	$u = x, v = \ln y$	$v = c + bu (c = \ln a)$
$y = ae^{b/x}$	$u = 1/x, v = \ln y$	$v = c + bu (c = \ln a)$
$y = 1/(a + be^{-x})$	$u = e^{-x}, v = 1/y$	$v = a + bu$

#### 2. 多项式回归

在曲线回归中, 比较困难的是选择合适的曲线类型。有的曲线也不一定经变