

一元线性回归

——最小二乘估计

主讲：黎雅莲



变量与变量之间的关系?

一、确定性关系

当一个变量给定时，就确定另一个变量的值与之对应。

某种商品的销售额(y)与销售量(x)之间的函数关系:

$$y = p x \text{ (} p \text{ 为单价)}$$

圆的面积(S)与半径(R)之间的函数关系:

$$S = \pi R^2$$



身高与体重的关系？




人的脚掌的长度与身高的关系？

二、相关性关系

当一个变量给定时，受影响的另一个变量的值不能完全确定，而是在一定范围内变化。





函数关系

相关关系



我们以一个例子来建立一元线性回归模型：

例1 为研究某市居民家庭人均年消费支出 Y (百元)与人均年可支配收入 X (百元)之间的关系,2011年中国统计年鉴上收集了1985-2010年26年的统计数据。

年	1985	1986	1987	1988	1989	1990	1991	1992	1993	1994	1995	1996	1997
人均可支配收入 x_i (百元)	8.12	9.84	11.09	12.78	14.49	16.91	18.92	21.95	27.1	36.34	43.75	50.23	53.02
人均消费性支出 y_i (百元)	7.11	8.94	10.44	13.23	13.83	15.70	17.54	19.29	23.97	31.27	40.52	44.67	49.20
年	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010
人均可支配收入 x_i (百元)	54.43	58.28	61.76	65.72	72.38	80.94	92.21	102.44	115.70	137.15	157.09	171.91	191.00
人均消费性支出 y_i (百元)	49.57	53.77	54.72	57.25	63.60	71.18	79.73	86.23	93.99	108.76	122.69	135.07	147.55




图1 城镇居民人均年消费支出 y 与收入 x 之间的数据散点图

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






对从总体 (x, Y) 中抽取的一个样本
 $(x_1, Y_1), (x_2, Y_2), \dots, (x_n, Y_n)$


一元线性回归模型:

$$\begin{cases} Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i, & i = 1, 2, \dots, n \\ \varepsilon_i \sim N(0, \sigma^2), & i = 1, 2, \dots, n \\ \text{Cov}(\varepsilon_i, \varepsilon_j) = 0, & i \neq j, i, j = 1, 2, \dots, n \end{cases}$$



给定样本观测值为 $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$,

参数 β_0 和 β_1 的估计?



最小二乘法思想

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

$$Q(\hat{\beta}_0, \hat{\beta}_1) = \min Q(\beta_0, \beta_1)$$



最小二乘法(求解)

要求 $\min Q(\beta_0, \beta_1)$

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

$$\begin{cases} \left. \frac{\partial Q}{\partial \beta_0} \right|_{\beta_0 = \hat{\beta}_0} = -2 \sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i) = 0 \\ \left. \frac{\partial Q}{\partial \beta_1} \right|_{\beta_1 = \hat{\beta}_1} = -2 \sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i) x_i = 0 \end{cases}$$

$$\begin{cases} \sum_{i=1}^n e_i = 0 \\ \sum_{i=1}^n x_i e_i = 0 \end{cases}$$



$$\begin{cases} n \hat{\beta}_0 + n \bar{x} \hat{\beta}_1 = n \bar{y} \\ n \bar{x} \hat{\beta}_0 + \left(\sum_{i=1}^n x_i^2 \right) \hat{\beta}_1 = \sum_{i=1}^n x_i y_i \end{cases}$$

称为正则方程。

其中 $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i, \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$

系数行列式

$$D = \begin{vmatrix} n & n\bar{x} \\ n\bar{x} & \sum_{i=1}^n x_i^2 \end{vmatrix} = n \left(\sum_{i=1}^n x_i^2 - n\bar{x}^2 \right) = n \sum_{i=1}^n (x_i - \bar{x})^2$$

由于 x_i 不全相等，所以 $D \neq 0$ ，方程组有唯一解。



$$\begin{cases} \hat{\beta}_1 = \frac{L_{xy}}{L_{xx}} \\ \hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x} \end{cases} \quad \text{--- 最小二乘估计}$$


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

$$L_{xy} = \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \sum_{i=1}^n x_i y_i - n\bar{x}\bar{y}$$

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x \quad \text{--- 回归方程}$$



- ❖ 对于例1，应用EXCEL，在Excel平台上计算，工具栏里有“数据分析”，含有“回归”，按步骤输入数据。



计算结果(SUMMARY OUTPUT)

回归统计	
Multiple R	0.997635
R Square	0.995276
Adjusted R Square	0.995079
标准误差	2.8707
观测值	26

方差分析

	df	SS	MS	F	Significance F
回归分析	1	41666.55	41666.55	5056.056	2.0082E-29
残差	24	197.7821	8.24092		
总计	25	41864.33			

	Coefficients	标准误差	t Stat	P-value	下限 95.0%	上限 95.0%
Intercept	4.551596	0.901403	5.049459	3.67E-05	2.691192	6.412
X Variable 1	0.771799	0.010854	71.10595	2.0082E-29	0.749397	0.794201

$$\hat{y} = 4.5516 + 0.7718x$$

