

# 第 8 章 一元线性回归

# 内容提要

8.1 变量之间关系的度量

8.2 一元线性回归

8.3 利用回归方程进行预测

8.4 残差分析

## 8.1 变量之间关系的度量

变量之间的关系

相关关系的描述与测度

相关系数的显著性检验

# 变量之间的关系：函数关系

## 定义


设有两个变量 $x$ 和 $y$ ，变量 $y$ 随变量 $x$ 一起变化，并完全依赖于 $x$ ，当变量 $x$ 取某个数值时， $y$ 依据确定的关系取相应的值，则称  $y$ 是 $x$ 的函数，记为 $y=f(x)$ ，其中 $x$ 称为自变量， $y$ 称为因变量。

## 性质

函数关系是一一对应的确定关系

## 图示


各个观测点落在一条直线上。



## 例子

- 商品销售额 $y$ 与销售量 $x$ 的关系： $y=px$
- 圆的面积 $S$ 与半径 $R$ 的关系： $S= \pi R^2$

# 变量之间的关系：相关关系



## 描述

一个变量的取值 $y$ 不能由另一个变量 $x$ 唯一确定，即当变量 $x$ 取某个值时，变量 $y$ 的取值可能有多个。

## 性质

相关关系是不确定的数量关系


## 图示

各个观测点分布在直线周围。

## 例子

- 子女身高 $y$ 与父母身高 $x$ 之间的关系
- 收入水平 $y$ 与受教育程度 $x$ 之间的关系
- 粮食单位面积产量 $y$ 与施肥量 $x_1$ 、降雨量 $x_2$ 、温度 $x_3$ 之间的关系
- 商品消费 $y$ 与居民收入 $x$ 之间的关系
- 商品销售额 $y$ 与广告支出 $x$ 之间的关系

# 从相关到因果



# 相关分析的主要问题与假定


## 主要问题

- 变量之间**是否存在关系**？
- 如果存在关系，它们之间是什么样的关系？ **线性vs非线性**
- 变量之间的**关系强度**如何？
- 样本所反映的变量之间的关系能否代表总体变量之间的关系？ **显著性**


## 假定

- 两个变量之间是**线性关系**
- 两个变量都是**随机变量**


# 相关关系的描述与测度：散点图




不相关




正线性相关




完全正线性相关



非线性相关



负线性相关



完全负线性相关

# 相关关系的描述与测度：相关系数(一)

## 定义

相关系数 (correlation coefficient), 是根据样本数据计算的, 度量两个变量之间线性关系强度的统计量。

## 分类

- 总体相关系数:  $\rho$
- 样本相关系数:  $r$  (Pearson 相关系数)

## 公式

- 总体相关系数

$$\rho = \frac{\text{cov}(X, Y)}{\sqrt{D(X)}\sqrt{D(Y)}}$$

- 样本相关系数

$$r = \frac{n \sum xy - \sum x \sum y}{\sqrt{n \sum x^2 - (\sum x)^2} \cdot \sqrt{n \sum y^2 - (\sum y)^2}}$$

# 相关关系的描述与测度：相关系数(二)

## 性质

- $r$ 的取值范围 $[-1, 1]$ 。
- $r$ 具有对称性。即 $r_{xy} = r_{yx}$
- $r$ 的数值大小与原点和尺度无关。
- $r$ 是 $x$ 与 $y$ 之间线性关系的度量，不能用于描述非线性关系。
- $r$ 是 $x$ 与 $y$ 之间线性关系的度量，不一定意味着因果关系。

$r$  的取值区间、含义与关系类型

取值	含义	关系类型
$r = -1$	完全负相关	确定性关系
$-1 < r \leq -0.8$	高度负相关	不确定性关系
$-0.8 < r \leq -0.5$	中度负相关	
$-0.5 < r \leq -0.3$	低度负相关	
$-0.3 < r < 0$	弱负相关(视为不相关)	
$r = 0$	不相关	确定性关系
$0 < r < 0.3$	弱正相关(视为不相关)	不确定性关系
$0.3 \leq r < 0.5$	低度正相关	
$0.5 \leq r < 0.8$	中度正相关	
$0.8 \leq r < 1$	高度正相关	
$r = 1$	完全正相关	确定性关系

# 相关系数的显著性检验

## 总体相关系数与样本相关系数

- 总体相关系数： $\rho$ （未知）
- 样本相关系数： $r$ （依据样本计算）
- $r$ 是 $\rho$ 的近似估计，受抽样波动的影响

## $r$ 的抽样分布

- 当 $\rho \rightarrow -1$ 时， $r$ 呈现出右偏分布
- 当 $\rho \rightarrow 1$ 时， $r$ 呈现出左偏分布
- 当 $\rho \rightarrow 0$ ，且 $n \rightarrow +\infty$ 时， $r$ 接近正态分布

## $r$ 的显著性检验

- 检验方式： $t$ 检验
- 检验内容：是否存在线性相关关系

## $r$ 的显著性检验步骤

- 提出假设：

$$H_0: \rho = 0$$

$$H_1: \rho \neq 0$$

- 计算检验统计量

$$t = |r| \sqrt{\frac{n-2}{1-r^2}} \sim t(n-2)$$

- 确定显著性水平 $\alpha$ ，做出统计决策

若 $|t| > t_{\alpha/2}$ ，拒绝 $H_0$

若 $|t| < t_{\alpha/2}$ ，不能拒绝 $H_0$

# 例子：背景与数据

## 例子

某大型商业银行在多个地区设有分行，其业务主要是进行基础设施建设、国家重点项目建设、固定资产投资等项目的贷款。

近年来，该银行的贷款额平稳增长，但不良贷款额也有较大比例的增长，这给银行业务的发展带来较大压力。


管理者希望知道：

- 不良贷款是否与贷款余额、累计应收贷款、贷款项目个数、固定资产投资额等因素有关？
- 如果有关，它们之间是什么样的关系？
- 关系强度如何？


	A	B	C	D	E	F
1	分行编号	不良贷款(亿元)	各项贷款余额(亿元)	本年累计应收贷款(亿元)	贷款项目个数(个)	本年固定资产投资额(亿元)
2	1	0.9	67.3	6.8	5	51.9
3	2	1.1	111.3	19.8	16	90.9
4	3	4.8	173.0	7.7	17	73.7
5	4	3.2	80.8	7.2	10	14.5
6	5	7.8	199.7	16.5	19	63.2
7	6	2.7	16.2	2.2	1	2.2
8	7	1.6	107.4	10.7	17	20.2
9	8	12.5	185.4	27.1	18	43.8
10	9	1.0	96.1	1.7	10	55.9
11	10	2.6	72.8	9.1	14	64.3
12	11	0.3	64.2	2.1	11	42.7
13	12	4.0	132.2	11.2	23	76.7
14	13	0.8	58.6	6.0	14	22.8
15	14	3.5	174.6	12.7	26	117.1
16	15	10.2	263.5	15.6	34	146.7
17	16	3.0	79.3	8.9	15	29.9
18	17	0.2	14.8	0.6	2	42.1
19	18	0.4	73.5	5.9	11	25.3
20	19	1.0	24.7	5.0	4	13.4
21	20	6.8	139.4	7.2	28	64.3
22	21	11.6	368.2	16.8	32	163.9
23	22	1.6	95.7	3.8	10	44.5
24	23	1.2	109.6	10.3	14	67.9
25	24	7.2	196.2	15.8	16	39.7
26	25	3.2	102.2	12.0	10	97.1

# 例子：散点图


## 不良贷款与贷款余额的散点图




## 不良贷款与累计应收贷款的散点图



## 不良贷款与贷款项目个数的散点图



## 不良贷款与固定资产投资额的散点图



# 例子：相关系数

	A	B	C	D	E	F
1		不良贷款	各项贷款余额	累计应收贷款	贷款项目个数	固定资产投资额
2	不良贷款	1				
3	各项贷款余额	0.843571	1			
4	累计应收贷款	0.731505	0.678772	1		
5	贷款项目个数	0.700281	0.848416	0.585831	1	
6	固定资产投资额	0.518518	0.779702	0.472431	0.746646	1

# 例子：相关系数的显著性检验

检验：不良贷款与贷款余额之间的相关系数显著性 ( $\alpha = 0.05$ )

## 步骤

- 提出假设： $H_0: \rho = 0$ ;  $H_1: \rho \neq 0$
- 计算检验统计量

$$t = |0.8436| \sqrt{\frac{25 - 2}{1 - 0.8436^2}} = 7.5344$$

- 根据显著性水平 $\alpha = 0.05$ ，查表得到临界值： $t_{\alpha/2}(n - 2) = 2.069$ 。由于 $t = 7.5344 > 2.069$ ，故拒绝 $H_0$ ，即不良贷款与贷款余额之间存在着显著的正相关关系。

	A	B	C	D	E
1		不良贷款	各项贷款余额	累计应收贷款	贷款项目个数
2	各项贷款余额	7.533515			
3	累计应收贷款	5.145188	4.432870		
4	贷款项目个数	4.704564	7.686824	3.466726	
5	固定资产投资额	2.908224	5.971918	2.570663	5.382848

## 8.2 一元线性回归

一元线性回归模型

参数的最小二乘估计

回归直线的拟合优度

显著性检验

# 什么是回归分析

## 回归分析解决的问题

- 确定变量关系


从一组样本数据出发，确定变量之间的数学关系式

- 统计检验

对这些关系式的可信程度进行各种统计检验，并从影响某一特定变量的诸多变量中找出哪些变量的影响显著，哪些不显著

- 预测

利用所求的关系式，根据一个或几个变量的取值来预测或控制另一个特定变量的取值，并给出这种预测或控制的精确程度



# 一元线性回归

## 定义

回归中只涉及一个自变量 $x$ ，且因变量 $y$ 与自变量 $x$ 之间为线性关系的回归。

## 说明

- 自变量 $x$ ：解释变量
- 因变量 $y$ ：被解释变量
- 一元：一个解释变量 $x$
- 线性：因变量 $y$ 与自变量 $x$ 之间呈现**直线关系**。

# 一元线性回归模型

## 基本假定

假定1: 因变量 $y$ 与自变量 $x$ 之间具有线性关系。

假定2: 在重复抽样中, 自变量 $x$ 的取值是固定的, 即假定 $x$ 是非随机的。

假定3: 误差项 $\varepsilon$ 是一个期望值为0的随机变量, 即 $E(\varepsilon) = 0$ 。

假定4: 对于所有的 $x$ 值,  $\varepsilon$ 的方差 $\sigma^2$ 都相同。

假定5: 误差项 $\varepsilon$ 是一个服从正态分布的随机变量, 且相互独立, 即 $\varepsilon \sim N(0, \sigma^2)$ 。

## 一元线性回归模型


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

### 说明

- $y$ 由线性部分 $\beta_0 + \beta_1 x$ 和误差项 $\varepsilon$ 构成
- $\beta_0 + \beta_1 x$ : 表示 $x$ 的变化引起 $y$ 的变化
- $\varepsilon$ : 表示除了 $x$ 之外的所有随机因素对 $y$ 的影响
- $\beta_0$ 和 $\beta_1$ : 模型的参数

### 问题

- $y$ 与 $x$ 之间是何种关系? 确定性 vs 不确定性
- 如何体现?



# 一元线性回归方程

## 回归方程的定义

描述因变量 $y$ 的期望值如何依赖于自变量 $x$ 的方程。

## 一元线性回归方程（总体）

$$E(y) = \beta_0 + \beta_1 x$$

## 说明

- 方程图示为一条直线：总体回归线
- $\beta_0$ ：总体回归线的截距
- $\beta_1$ ：总体回归线的斜率

## 估计的回归方程（样本）

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x$$

## 说明

- 总体回归参数 $\beta_0$ 和 $\beta_1$ 未知
- 样本回归参数 $\hat{\beta}_0$ 和 $\hat{\beta}_1$ 是对总体参数的估计
- $\hat{\beta}_0$ ：样本回归线的截距
- $\hat{\beta}_1$ ：样本回归线的斜率

# 参数的最小二乘估计

参数估计方法：最小二乘法 (Least Squares)

提出：卡尔·高斯 (1777-1855)

目标函数


$$\min_{(\beta_0, \beta_1)} Q = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i)^2$$

原理

寻找最小化残差平方和的参数 $\beta_0, \beta_1$ 的取值。

几何含义

寻找所有的点到直线的距离平方和最小的直线。



# 参数的最小二乘估计：求解

目标函数：

$$\min_{(\beta_0, \beta_1)} Q = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i)^2$$

求解：

$$F.O.C \begin{cases} \frac{\partial Q}{\partial \beta_0} = -2 \sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i) = 0 \\ \frac{\partial Q}{\partial \beta_1} = -2 \sum_{i=1}^n x_i (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i) = 0 \end{cases} \Rightarrow \begin{cases} \hat{\beta}_1 = \frac{n \sum_{i=1}^n x_i y_i - (\sum_{i=1}^n x_i)(\sum_{i=1}^n y_i)}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} \\ \hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x} \end{cases}$$

# 参数的最小二乘估计：例子

求解：不良贷款对贷款余额的回归方程


$$\begin{cases} \hat{\beta}_1 = \frac{25 \times 17080.14 - 3006.7 \times 93.2}{25 \times 516543.37 - (3006.7)^2} = 0.037895 \\ \hat{\beta}_0 = 3.728 - 0.037895 \times 120.268 = -0.8295 \end{cases}$$

回归方程

$$\hat{y} = -0.8295 + 0.03795x$$

经济含义

贷款余额每增加1亿元，不良贷款平均增加0.037895亿元。




# 回归直线的拟合优度：判定系数

方差分解：

$$\underbrace{\sum_{i=1}^n (y_i - \bar{y})^2}_{\text{总平方和 (SST)}} = \underbrace{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}_{\text{回归平方和 (SSR)}} + \underbrace{\sum_{i=1}^n (y_i - \hat{y})^2}_{\text{残差平方和 (SSE)}}$$

判定系数 $R^2$ ：

$$R^2 = \frac{SSR}{SST} = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$



说明：

- $R^2 \rightarrow 1$ ，说明回归方程拟合的越
- $R^2 \rightarrow 0$ ，说明回归方程拟合的越差
- 对于一元回归，判定系数等于相关系数的平方，即 $R^2 = r^2$

# 回归直线的拟合优度：判定系数的计算

例子：

计算不良贷款对贷款余额回归的判定系数，并解释其意义

$$R^2 = \frac{SSR}{SST} = \frac{222.4860}{312.6504} = 0.7116 = 71.16\%$$

经济含义：

在不良贷款取值的变动中，有71.16%是由贷款余额所决定的。

# 回归直线的拟合优度：估计的标准误差

公式

$$s_e = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n-2}} = \sqrt{\frac{SSE}{n-2}} = \sqrt{MSE}$$

作用：度量实际观测值 $y_i$ 与回归估计值 $\hat{y}_i$ 之间的差异程度。

例子：计算不良贷款对贷款余额回归的估计标准误差，并解释其意义

$$s_e = \sqrt{\frac{SSE}{n-2}} = \sqrt{\frac{SST - SSR}{n-2}} = \sqrt{\frac{312.6504 - 222.4860}{25-2}} = 1.9799(\text{亿元})$$

经济含义：根据贷款余额估计不良贷款时，估计值的平均误差是1.9799亿元。

# 显著性检验

## “显著性”的含义

某个(某些)自变量(系数)的影响是否显著不同于零。

**目的：** 回归模型（系数）是否反映了自变量X和因变量Y之间的真实关系。

## 步骤

- 提出假设  $H_0$ : 系数等于零（原假设）  $H_1$ : 系数不等于零（备择假设）
- 以样本数据为基础，计算检验统计量(F统计量，或t统计量)
- 根据给定的**显著性水平**（如 $\alpha=0.05$ ），查表获得临界值，比较检验统计量与临界值的大小：
  - 检验统计量 > 临界值，系数显著，拒绝 $H_0$ ；
  - 检验统计量 < 临界值，系数不显著，不能拒绝 $H_0$ 。

## 类型

- 线性关系检验（回归方程的整体显著性）：**多个变量系数**的显著性的**联合检验**，通常采用**F检验**。
- 回归系数检验（单个变量系数的显著性）：**单个变量系数**的显著性检验，通常采用**t检验**。

# 显著性检验：线性关系检验

## 含义

检验自变量x与因变量y之间的线性关系是否显著（回归方程的整体显著性检验）

## 实质

所有自变量X的系数是否同时为零

方式：F统计量

## 步骤

- 提出假设

$H_0: \beta_1 = 0$  (线性关系不显著)

$H_1: \beta_1 \neq 0$  (线性关系显著)

- 计算检验统计量

$$F = \frac{SSR/1}{SSE/(n-2)} = \frac{MSR}{MSE} \sim F(1, n-2)$$

- 确定显著性水平 $\alpha$ ，并依据分子自由度1和分母自由度 $n-2$ ，查找临界值 $F_\alpha$
- 做出统计决策

若 $F > F_\alpha$ ，拒绝 $H_0$

若 $F < F_\alpha$ ，不能拒绝 $H_0$

# 显著性检验：线性关系检验的例子

检验：不良贷款与贷款余额之间线性关系

- 提出假设

$H_0: \beta_1 = 0$  (线性关系不显著)

$H_1: \beta_1 \neq 0$  (线性关系显著)

- 计算检验统计量

$$F = \frac{SSR/1}{SSE/(n-2)} = \frac{222.48598/1}{90.164421/(25-2)} = 56.753844$$

- 确定显著性水平 $\alpha = 0.05$ , 并依据分子自由度1和分母自由度n-2, 查表知, 临界值 $F_\alpha = 4.28$
- 做出统计决策

统计量F大于临界值 $F_\alpha$ , 拒绝 $H_0$ , 不得不接受 $H_1$ , 即不良贷款与贷款余额之间的线性关系显著

	A	B	C	D	E	F
1	方差分析					
2		df	SS	MS	F	Significance F
3	回归分析	1	110252.7	110252.7	56.75384	1.18349E-07
4	残差	23	44680.88	1942.647		
5	总计	24	154933.6			

# 显著性检验：回归系数检验

## 含义

检验某个自变量x与因变量y的影响是否显著（单个变量系数的显著性）

## 实质

某个自变量X的系数是否为零

方式：t统计量

## 说明：

在一元线性回归中，回归系数检验与线性关系的检验等效： $t_{n-2}^2 = F_{1,n-2}$

## 步骤

- 提出假设

$$H_0: \beta_1 = 0 \text{ (影响不显著)}$$

$$H_1: \beta_1 \neq 0 \text{ (影响显著)}$$

- 计算检验统计量

$$t = \frac{\hat{\beta}_1}{s_{\hat{\beta}_1}} \sim t(n-2)$$

- 确定显著性水平 $\alpha$ ，并依据自由度，查找临界值 $t_{\alpha/2}$
- 做出统计决策

若 $|t| > t_{\alpha/2}$ ，拒绝 $H_0$

若 $|t| < t_{\alpha/2}$ ，不能拒绝 $H_0$

# 显著性检验：回归系数检验的例子

检验：贷款余额对不良贷款的影响是否显著

- 提出假设

$$H_0: \beta_1 = 0 \text{ (影响不显著)}$$

$$H_1: \beta_1 \neq 0 \text{ (影响显著)}$$

- 计算检验统计量

$$t = \frac{\hat{\beta}_1}{s_{\hat{\beta}_1}} = \frac{0.037895}{0.005030} = 7.533515$$

- 确定显著性水平 $\alpha = 0.05$ ，并依据自由度23，查表知，临界值 $t_{\alpha/2} = 2.201$
- 做出统计决策

统计量 $t$ 大于临界值 $t_{\alpha/2}$ ，拒绝 $H_0$ ，不得不接受 $H_1$ ，即贷款余额对不良贷款的影响显著

	A	B	C	D	E
1		Coefficients	标准误差	t Stat	P-value
2	Intercept	-0.829521	0.723043	-1.147263	0.263068
3	X Variable	0.037895	0.005030	7.533515	0.000000

# 回归模型的评价：“好”模型的四个标准

## 标准1：符合预期

- 含义：即回归系数符号与理论或事先预期一致。
- 例子：在不良贷款与贷款余额的回归中，我们预期：贷款余额越多，不良贷款也可能会越多，即回归系数的值应该是正的。在回归方程中，贷款余额的回归系数  $\hat{\beta}_1 = 0.03795$ ，符号为正，符合预期。

## 标准2：统计显著

- 含义：回归系数通过t检验和F检验。
- 例子：在不良贷款与贷款余额的回归中，二者之间为正的线性关系，而且，对回归系数  $\hat{\beta}_1$  的t检验和F检验结果表明：不良贷款与贷款余额之间的线性关系是统计上显著的。

# 回归模型的评价：“好”模型的四个标准

## 标准3：解释程度高

- 含义：模型具有较高的判定系数 $R^2$ 。
- 例子：在不良贷款与贷款余额的回归中，判定系数 $R^2=71.16\%$ ，解释了不良贷款变差的2/3以上，说明模型的解释程度不错。

## 标准4：好的残差

- 含义：残差 $e$ 接近，或者服从正态分布。
- 依据： $\varepsilon \sim N(0, \sigma^2)$ ，残差 $e$ 是误差项 $\varepsilon$ 的替代，也应服从正态分布
- 重要性：模型的F检验和t检验均依赖于残差的正态分布假设。若残差不服从正态分布，则上述检验无效。
- 检验方法：直方图，JB统计量
- 补救措施：识别出未知的自变量，增大样本容量等

## 8.3 利用回归方程 进行预测

点估计

区间估计

# 利用回归方程进行预测

## 含义

预测 (Predict)，是指通过自变量 $x$ 的取值来预测因变量 $y$ 的取值。

## 例子

根据不良贷款 $y$ 与贷款余额 $x$ 的回归方程，给定一个贷款余额 $x$ 的取值，就可以得到一个不良贷款 $y$ 的预测值。

## 类型

- 点估计：对于 $x$ 的一个特定值 $x_0$ ，根据回归方程得到 $y$ 的一个估计值。
  - $y$ 的平均值的点估计
  - $y$ 的个别值的点估计
- 区间估计：对于 $x$ 的一个特定值 $x_0$ ，根据回归方程得到 $y$ 的一个估计区间。
  - $y$ 的平均值的置信区间估计
  - $y$ 的个别值的预测区间估计

# 点估计：平均值 vs 个别值

## 平均值的点估计

- 含义

对于自变量 $x$ 的一个给定值 $x_0$ ，求因变量 $y$ 的平均值的一个估计值 $E(y_0)$ 。

- 说明： $x_0$ 为给定值，并非样本中的真实值

- 例子

给定贷款余额为100亿元时，估计所有分行不良贷款的平均值，即：

$$E(y_0) = -0.8295 + 0.037895 \times 100 = 2.96(\text{亿元})$$

## 个别值的点估计

- 含义

对于自变量 $x$ 的一个给定值 $x_0$ ，求因变量 $y$ 的个别值的一个估计值 $\hat{y}_0$ 。

- 说明： $x_0$ 为样本中的真实值

- 例子

给定某分行贷款余额为72.8亿元时，估计该分行不良贷款的个别值，即：

$$\hat{y}_0 = -0.8295 + 0.037895 \times 72.8 = 1.93(\text{亿元})$$

# 区间估计：置信区间

## 含义

利用估计的回归方程，对于自变量 $x$ 的一个给定值 $x_0$ ，求出因变量 $y$ 的平均值的估计区间，即为**置信区间** (confidence interval)。

- 说明：平均值→置信区间
- 公式

$$\hat{y}_0 \pm t_{\alpha/2} s_e \sqrt{\frac{1}{n} + \frac{(x_0 - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2}}$$

## 例子

求解：当贷款余额为100亿元时，不良贷款95%置信水平下的置信区间。

解：已知 $n = 25$ ,  $\hat{y}_0 = 2.96$ ,  $s_e = 1.9799$

$$t_{\alpha/2}(25 - 2) = 2.069$$

置信区间：

$$2.96 \pm 2.069 \times 1.9799 \times \sqrt{\frac{1}{25} + \frac{(100 - 120.268)^2}{154933.5744}}$$

$$\text{即 } 2.1141 \leq E(y_0) \leq 3.8059$$

含义：当贷款余额为100亿元时，不良贷款的平均值在2.1141亿元到3.8059亿元之间

# 区间估计：预测区间

## 含义

利用估计的回归方程，对于自变量 $x$ 的一个给定值 $x_0$ ，求出因变量 $y$ 的个别值的估计区间，即为预测区间(Prediction interval)。

- 说明：个别值→预测区间
- 公式

$$\hat{y}_0 \pm t_{\alpha/2} s_e \sqrt{1 + \frac{1}{n} + \frac{(x_0 - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2}}$$

## 例子

求解：当某分行的贷款余额为72.8亿元时，不良贷款95%置信水平下的预测区间。

解：已知 $n = 25$ ,  $\hat{y}_0 = 1.93$ ,  $s_e = 1.9799$

$$t_{\alpha/2}(25 - 2) = 2.069$$

预测区间：

$$1.93 \pm 2.069 \times 1.9799 \times \sqrt{1 + \frac{1}{25} + \frac{(72.8 - 120.268)^2}{154933.5744}}$$


$$\text{即 } -2.2766 \leq \hat{y}_0 \leq 6.1366$$

含义：当某分行贷款余额为72.8亿元时，不良贷款的预测值在-2.2766亿元到6.1366亿元之间

# 区间估计：置信区间 vs 预测区间

	A	B	C	D	E	F	G	H
1	分行	不良贷款	贷款余额	预测 $y$	置信区间		预测区间	
2	编号	( $y$ )	( $x$ )		置信下限	置信上限	预测下限	预测上限
3	1	0.9	67.3	1.7208	0.7333	2.7083	-2.4964	5.9380
4	2	1.1	111.3	3.3882	2.5636	4.2128	-0.7939	7.5702
5	3	4.8	173	5.7263	4.7401	6.7124	1.5094	9.9431
6	4	3.2	80.8	2.2324	1.3159	3.1489	-1.9687	6.4335
7	5	7.8	199.7	6.7381	5.5742	7.9019	2.4761	11.0000
8	6	2.7	16.2	-0.2156	-1.5737	1.1424	-4.5346	4.1034
9	7	1.6	107.4	3.2404	2.4102	4.0705	-0.9428	7.4235
10	8	12.5	185.4	6.1962	5.1328	7.2595	1.9606	10.4317
11	9	1.0	96.1	2.8122	1.9551	3.6692	-1.3764	7.0007
12	10	2.6	72.8	1.9292	0.9725	2.8859	-2.2809	6.1393
13	11	0.3	64.2	1.6033	0.5975	2.6092	-2.6182	5.8248
14	12	4.0	132.2	4.1802	3.3515	5.0088	-0.0027	8.3630
15	13	0.8	58.6	1.3911	0.3504	2.4319	-2.8388	5.6211
16	14	3.5	174.6	5.7869	4.7914	6.7824	1.5678	10.0059
17	15	10.2	263.5	9.1557	7.4547	10.8567	4.7170	13.5945
18	16	3.0	79.3	2.1755	1.2519	3.0991	-2.0271	6.3782
19	17	0.2	14.8	-0.2687	-1.6384	1.1010	-4.5913	4.0540
20	18	0.4	73.5	1.9557	1.0028	2.9087	-2.2535	6.1650
21	19	1.0	24.7	0.1065	-1.1821	1.3951	-4.1912	4.4041
22	20	6.8	139.4	4.4530	3.6099	5.2962	0.2673	8.6387
23	21	11.6	368.2	13.1233	10.4160	15.8306	8.2102	18.0364
24	22	1.6	95.7	2.7970	1.9387	3.6553	-1.3918	6.9858
25	23	1.2	109.6	3.3237	2.4969	4.1505	-0.8587	7.5062
26	24	7.2	196.2	6.6054	5.4671	7.7437	2.3504	10.8604
27	25	3.2	102.2	3.0433	2.2027	3.8839	-1.1419	7.2285

# 区间估计：置信区间 vs 预测区间



## 8.4 残差分析

残差与残差图

标准化

# 残差与残差图

## 残差

利用因变量的观测值 $y_i$ 与根据估计的回归方程求出的预测值 $\hat{y}_i$ 。

## 公式

$$e_i = y_i - \hat{y}_i$$

## 含义

残差反映了用估计的回归方程去预测而引起的误差。


## 残差图

- 残差与X的XY散点图
- 残差与 $\hat{y}_i$ 的XY散点图
- 标准化残差图


## 作用

用于判断误差 $\varepsilon$ 的假定是否成立


# 残差图：形态与判别



理想模式



异方差



模型设定有误

# 标准化残差与残差图

## 标准化残差

残差除以它的标准差。

## 公式

$$z_{e_i} = \frac{e_i}{s_e} = \frac{y_i - \hat{y}_i}{s_e}$$

## Excel

$$z_{e_i} = \frac{y_i - \hat{y}_i}{s_e \sqrt{1 - \left( \frac{1}{n} + \frac{(x_i - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \right)}}$$

## 标准化残差图

- 作用

用以直观地判断误差项服从正态分布这一假定是否成立


- 原理

若误差项服从正态分布，则标准化残差服从标准正态分布


- 含义

依据经验法则，在标准化残差图中，大约有95%的标准化残差在-2到+2之间

# 残差图 vs 标准化残差图



不良贷款对贷款余额回归的残差图



# 本章小结

