

応用システム工学

第六回 回帰分析

平成24年07月06日
重回帰分析

2012/07/06

1

偏相関係数

- 目的変数 y, x_1 を説明変数 x_2, x_3, \dots, x_p から予測する二つの重回帰モデル

$$\begin{cases} y_i = c_0 + c_2 x_{2i} + \dots + c_p x_{pi} + e_i \\ x_{1i} = d_0 + d_2 x_{2i} + \dots + d_p x_{pi} + e'_i \end{cases}$$

– 予測誤差の平方和

$$\begin{cases} F(c_0, c_2, \dots, c_p) = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n \{y_i - (c_0 + c_2 x_{2i} + \dots + c_p x_{pi})\}^2 \\ F'(d_0, d_2, \dots, d_p) = \sum_{i=1}^n e_i'^2 = \sum_{i=1}^n \{x_{1i} - (d_0 + d_2 x_{2i} + \dots + d_p x_{pi})\}^2 \end{cases}$$

2012/07/06

2

偏相関係数

– 予測誤差の平方和の最小化(最小二乗法)

$$\left\{ \begin{array}{l} \frac{\partial}{\partial c_0} F(c_0, c_2, \dots, c_p) = 0 \\ \frac{\partial}{\partial c_2} F(c_0, c_2, \dots, c_p) = 0 \\ \vdots \\ \frac{\partial}{\partial c_p} F(c_0, c_2, \dots, c_p) = 0 \end{array} \right. \quad \left\{ \begin{array}{l} \frac{\partial}{\partial d_0} F'(d_0, d_2, \dots, d_p) = 0 \\ \frac{\partial}{\partial d_2} F'(d_0, d_2, \dots, d_p) = 0 \\ \vdots \\ \frac{\partial}{\partial d_p} F'(d_0, d_2, \dots, d_p) = 0 \end{array} \right.$$

2012/07/06

3

偏相関係数

– 予測誤差の平方和の最小化(最小二乗法)

• y_i に対して

$$\left\{ \begin{array}{l} -2 \sum_{i=1}^n \{y_i - (c_0 + c_2 x_{2i} + \dots + c_p x_{pi})\} = 0 \\ -2 \sum_{i=1}^n x_{2i} \{y_i - (c_0 + c_2 x_{2i} + \dots + c_p x_{pi})\} = 0 \\ \vdots \\ -2 \sum_{i=1}^n x_{pi} \{y_i - (c_0 + c_2 x_{2i} + \dots + c_p x_{pi})\} = 0 \end{array} \right.$$

2012/07/06

4

偏相関係数

$$\begin{bmatrix} s_{22} & s_{23} & \cdots & s_{2p} \\ \vdots & & & \\ s_{j2} & s_{j3} & & s_{jp} \\ \vdots & & & \\ s_{p2} & s_{p3} & \cdots & s_{pp} \end{bmatrix} \begin{bmatrix} \hat{c}_2 \\ \hat{c}_3 \\ \vdots \\ \hat{c}_p \end{bmatrix} = \begin{bmatrix} s_{y2} \\ \vdots \\ s_{yj} \\ \vdots \\ s_{yp} \end{bmatrix} \quad \begin{bmatrix} s_{22} & s_{23} & \cdots & s_{2p} \\ \vdots & & & \\ s_{j2} & s_{j3} & & s_{jp} \\ \vdots & & & \\ s_{p2} & s_{p3} & \cdots & s_{pp} \end{bmatrix} \begin{bmatrix} \hat{d}_2 \\ \hat{d}_3 \\ \vdots \\ \hat{d}_p \end{bmatrix} = \begin{bmatrix} s_{12} \\ \vdots \\ s_{1j} \\ \vdots \\ s_{1p} \end{bmatrix}$$

$$\begin{cases} \hat{c}_0 = \bar{y} - (\hat{c}_2 \bar{x}_2 + \hat{c}_3 \bar{x}_3 + \cdots + \hat{c}_p \bar{x}_p) \\ \hat{d}_0 = \bar{x}_1 - (\hat{d}_2 \bar{x}_2 + \hat{d}_3 \bar{x}_3 + \cdots + \hat{d}_p \bar{x}_p) \end{cases}$$

目的変数 y , x_1 の, 説明変数 x_2, x_3, \dots, x_p に対する線形重回帰式

$$\begin{cases} y = \hat{c}_0 + \hat{c}_2 x_2 + \hat{c}_3 x_3 + \cdots + \hat{c}_p x_p \\ x_1 = \hat{d}_0 + \hat{d}_2 x_2 + \hat{d}_3 x_3 + \cdots + \hat{d}_p x_p \end{cases}$$

重回帰係数 $\hat{c}_j, \hat{d}_j \quad j = 2, 3, \dots, p$

2012/07/06

7

偏相関係数

• 予測誤差

$$\begin{cases} u_i = y_i - (c_0 + c_2 x_{2i} + \cdots + c_p x_{pi}) \\ v_i = x_{1i} - (d_0 + d_2 x_{2i} + \cdots + d_p x_{pi}) \end{cases} \quad i = 1, 2, \dots, n$$

– 予測誤差 u, v の単相関係数

$$r_{y1 \cdot 23 \dots p} = \frac{s_{uv}}{\sqrt{s_{uu} s_{vv}}} \quad s_{uu} = \frac{1}{n} \sum_{i=1}^n (u_i - \bar{u})^2 \quad s_{vv} = \frac{1}{n} \sum_{i=1}^n (v_i - \bar{v})^2$$

$$s_{uv} = \frac{1}{n} \sum_{i=1}^n (u_i - \bar{u})(v_i - \bar{v}) \quad \text{ただし} \quad \bar{u} = \frac{1}{n} \sum_{i=1}^n u_i \quad \bar{v} = \frac{1}{n} \sum_{i=1}^n v_i$$

y, x_1 から, x_2, x_3, \dots, x_p の回帰が消去された時の偏相関係数
→ (x_2, x_3, \dots, x_p) の影響を除いた y, x_1 の相関係数

2012/07/06

8

偏相関係数

- 偏相関の意味
 - y の残差 u は x_2, \dots, x_p 依存する変動を y から除いたもの
 - X_1 の残差 v は x_2, \dots, x_p に依存する変動を x_1 から除いたもの
 - 予測誤差 u, v の相関係数は, y と x_1 から各々 x_2, \dots, x_p に依存する変動を除いた相関係数

2012/07/06

9

標本と母数の関係 単回帰

- 母回帰係数 a_0, a_1
 - 予測値 $a_0 + a_1 x_i$
 - 標本 y_i, x_i
 - 誤差 $e_i = y_i - (a_0 + a_1 x_i)$
(残差ではない)
- 標本回帰係数 \hat{a}_0, \hat{a}_1
 - 残差 $y_i - (\hat{a}_0 + \hat{a}_1 x_i)$
- 母集団を求めることは難しいので, 標本から母集団を推定する

2012/07/06

10

母回帰係数の推定

- 仮定

- 誤差の期待値 $E[e_i] = 0$
- 誤差の分散 $V[e_i] = \sigma^2$
- 誤差は無相関 $Cov[e_i, e_j] = 0 (i \neq j)$
- 誤差は正規分布 $N(0, \sigma^2)$

- 標本回帰係数の期待値との関係を求める

- 標本回帰係数 \hat{a}_0, \hat{a}_1

2012/07/06

11

母回帰係数の推定

- 標本回帰係数 \hat{a}_1 の期待値 $E[\hat{a}_1]$

$$\hat{a}_1 = \frac{s_{xy}}{s_{xx}} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

$$y_i = a_0 + a_1 x_i + e_i$$

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i = \frac{1}{n} \sum_{i=1}^n (a_0 + a_1 x_i + e_i)$$

$$= a_0 + a_1 \bar{x}$$

$$= \frac{\sum_{i=1}^n (x_i - \bar{x})(a_0 + a_1 x_i + e_i - [a_0 + a_1 \bar{x}])}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

$$= \frac{\sum_{i=1}^n (x_i - \bar{x})(a_1[x_i - \bar{x}] + e_i)}{\sum_{i=1}^n (x_i - \bar{x})^2} = a_1 + \frac{\sum_{i=1}^n (x_i - \bar{x})e_i}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

2012/07/06

12

母回帰係数の推定

- 標本回帰係数 \hat{a}_1 の期待値 $E[\hat{a}_1]$

$$E[\hat{a}_1] = E\left[a_1 + \frac{\sum_{i=1}^n (x_i - \bar{x})e_i}{\sum_{i=1}^n (x_i - \bar{x})^2} \right] = E[a_1] + E\left[\frac{\sum_{i=1}^n (x_i - \bar{x})e_i}{\sum_{i=1}^n (x_i - \bar{x})^2} \right]$$

– 確率変数 e_i なので, 第二項は0

$$E[\hat{a}_1] = E[a_1] = a_1$$

2012/07/06

13

母回帰係数の推定

- 標本回帰係数 \hat{a}_1 の分散 $V[\hat{a}_1]$

$$\begin{aligned} V[\hat{a}_1] &= E[(\hat{a}_1 - E[\hat{a}_1])^2] = E[(\hat{a}_1 - a_1)^2] \\ &= E\left[\left(a_1 + \frac{\sum_{i=1}^n (x_i - \bar{x})e_i}{\sum_{i=1}^n (x_i - \bar{x})^2} - a_1 \right)^2 \right] \\ &= E\left[\left(\frac{\sum_{i=1}^n (x_i - \bar{x})e_i}{\sum_{i=1}^n (x_i - \bar{x})^2} \right)^2 \right] \end{aligned}$$

2012/07/06

14

母回帰係数の推定

• つづき

$$V[\hat{a}_1] = E \left[\frac{\sum_{i=1}^n \sum_{j=1}^n (x_i - \bar{x})(x_j - \bar{x}) e_i e_j}{\left\{ \sum_{i=1}^n (x_i - \bar{x})^2 \right\}^2} \right]$$

$$= E \left[\frac{\sum_{i=1}^n (x_i - \bar{x})^2 e_i^2}{\left\{ \sum_{i=1}^n (x_i - \bar{x})^2 \right\}^2} \right]$$

$$= \frac{\sigma^2 \sum_{i=1}^n (x_i - \bar{x})^2}{\left\{ \sum_{i=1}^n (x_i - \bar{x})^2 \right\}^2} = \frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

$$\begin{aligned} \text{Cov}[e_i, e_j] &= E[(e_i - E[e_i])(e_j - E[e_j])] \\ &= E[e_i e_j] = 0 \end{aligned}$$

$$\begin{aligned} V[e_i] &= E[e_i^2] - E[e_i]^2 \\ &= E[e_i^2] = \sigma^2 \end{aligned}$$

2012/07/06

15

母回帰係数の推定

- 標本回帰係数 \hat{a}_1 と母回帰係数 a_1 の関係

$$\hat{a}_1 = a_1 + \frac{\sum_{i=1}^n (x_i - \bar{x}) e_i}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

- 標本回帰係数 \hat{a}_1 の期待値 $E[\hat{a}_1]$

$$E[\hat{a}_1] = E[a_1] = a_1$$

- 標本回帰係数 \hat{a}_1 の分散 $V[\hat{a}_1]$

$$V[\hat{a}_1] = \frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

2012/07/06

16

母回帰係数の推定

- 標本回帰係数 \hat{a}_1 は誤差 e_i の一次関数として表される

$$\hat{a}_1 = a_1 + \frac{\sum_{i=1}^n (x_i - \bar{x})e_i}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

→ 標本の誤差が正規分布なので標本回帰係数も正規分布する

$$\hat{a}_1 \sim N\left(a_1, \frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2}\right)$$

– 標準正規分布化 $\frac{\hat{a}_1 - a_1}{\sigma^2} \sim N(0,1)$

- 期待値を引いて分散で割る

$$\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{\sigma^2} \rightarrow \text{ただし, } \sigma^2, a_1 \text{ は未知数}$$

2012/07/06

17

大数の法則

- 標本数 → 用いる母集団の数
- 標本サイズ → 母集団からとりだす標本の数
- 大数の法則 → 標本サイズを大きくすると、その期待値が母集団の期待値から離れた値となる確率は小さくなる
 - 標本平均の期待値 $E[\bar{X}_n]$ と分散 $V[\bar{X}_n]$ で評価
 - 標本 X_1, X_2, \dots, X_n は母集団と同じ確率分布 (平均 μ , 分散 σ^2) となる確率変数
 - 標本 X_1, X_2, \dots, X_n は独立

2012/07/06

18