

Αν το μοντέλο είναι $\underline{y} = \underline{X}\underline{\beta} + \underline{\varepsilon}$, $\underline{\varepsilon} \sim N_n(0, \sigma^2 I)$, $\underline{\beta} \in \mathfrak{R}^p$, $\text{rank}(\underline{X}) = p < n$,

έχω ότι $\hat{\underline{\beta}} = (\underline{X}^T \underline{X})^{-1} \underline{X}^T \underline{y}$, $\hat{\sigma}^2 = \frac{\underline{y}^T (\underline{I} - \underline{P}_V) \underline{y}}{n - p}$,

$\underline{\mu} = \underline{X}\underline{\beta}$ □ $\underline{\beta} = (\underline{X}^T \underline{X})^{-1} \underline{X}^T \underline{\mu}$ □ Η προβολή του $\underline{\mu}$ στο \mathfrak{R}^p .

Ισχύει το παρακάτω θεώρημα ανάλογα με το μοντέλο #1:

Θεώρημα Gauss-Markov:

Έστω $\underline{d} \in \mathfrak{R}^p$, σταθερό. Τότε η εκτιμήτρια $\underline{d}^T \hat{\underline{\beta}}$ είναι η μοναδική γραμμική εκτιμήτρια του $\underline{d}^T \underline{\beta}$ με ελάχιστη διασπορά.

Απόδειξη: Αφού $\underline{\beta} = (\underline{X}^T \underline{X})^{-1} \underline{X}^T \underline{\mu}$ □ $\underline{d}^T \underline{\beta} = \underbrace{\underline{d}^T (\underline{X}^T \underline{X})^{-1} \underline{X}^T}_{\underline{c}} \underline{\mu} = \underline{c}^T \underline{\mu}$ και άρα εφαρμόζω το θεώρημα Gauss-Markov για το μοντέλο #1.

Πόρισμα:

Η εκτιμήτρια ελαχίστων τετραγώνων $\hat{\underline{\beta}}$ είναι Α.Ο.Ε.Δ. του $\underline{\beta}$ κατά συνιστώσα.

Εφαρμογές: #1. Απλό γραμμικό μοντέλο

Έχω ότι $y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$, $i = 1, \dots, n$.

Γνωρίζω ότι $\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}$, $\hat{\beta}_1 = \frac{\sum (x_i - \bar{x}) y_i}{\sum (x_i - \bar{x})^2}$.

Θεωρώ $\underline{y} = \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix}$, $\underline{X} = \begin{pmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_n \end{pmatrix}$ και $\underline{\varepsilon} = \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix}$, οπότε $\underline{y} = \underline{X}\underline{\beta} + \underline{\varepsilon}$, $\underline{\beta} = \begin{pmatrix} \beta_0 \\ \beta_1 \end{pmatrix}$.

Έχω λοιπόν ότι $\hat{\underline{\beta}} = \begin{pmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \end{pmatrix} = (\underline{X}^T \underline{X})^{-1} \underline{X}^T \underline{y}$.

Όμως, $\underline{X}^T \underline{X} = \begin{pmatrix} 1 & 1 & \dots & 1 \\ x_1 & x_2 & \dots & x_n \end{pmatrix} \begin{pmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_n \end{pmatrix} = \begin{pmatrix} n & \sum_{i=1}^n x_i \\ \sum_{i=1}^n x_i & \sum_{i=1}^n x_i^2 \end{pmatrix}$.

Η ορίζουσα του $\underline{X}^T \underline{X}$ είναι $n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i \right)^2 = n \sum_{i=1}^n x_i^2 - n^2 \bar{x}^2 = n \sum_{i=1}^n (x_i - \bar{x})^2$.

Οπότε $(\underline{X}^T \underline{X})^{-1} = \frac{1}{n \sum_{i=1}^n (x_i - \bar{x})^2} \begin{bmatrix} \sum_{i=1}^n x_i^2 & -\sum_{i=1}^n x_i \\ -\sum_{i=1}^n x_i & n \end{bmatrix} = \frac{1}{n \sum_{i=1}^n (x_i - \bar{x})^2} \begin{bmatrix} \sum_{i=1}^n x_i^2 & -n\bar{x} \\ -n\bar{x} & n \end{bmatrix}$

Άρα $(\underline{X}^T \underline{X})^{-1} \underline{X}^T = \frac{1}{n \sum_{i=1}^n (x_i - \bar{x})^2} \begin{bmatrix} \sum_{i=1}^n x_i^2 & -n\bar{x} \\ -n\bar{x} & n \end{bmatrix} \begin{pmatrix} 1 & 1 & \dots & 1 \\ x_1 & x_2 & \dots & x_n \end{pmatrix}$

$$= \frac{1}{n \sum_{i=1}^n (x_i - \bar{x})^2} \begin{bmatrix} \sum x_i^2 - n\bar{x}x_1 & \sum x_i^2 - n\bar{x}x_2 & \dots & \sum x_i^2 - n\bar{x}x_n \\ -n\bar{x} + nx_1 & -n\bar{x} + nx_2 & \dots & -n\bar{x} + nx_n \end{bmatrix}.$$

$$\text{Άρα, } \underline{\hat{\beta}} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \underline{y} = \frac{1}{n \sum_{i=1}^n (x_i - \bar{x})^2} \begin{bmatrix} \sum x_i^2 - n\bar{x}x_1 & \dots & \sum x_i^2 - n\bar{x}x_n \\ -n\bar{x} + nx_1 & \dots & -n\bar{x} + nx_n \end{bmatrix} \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix}$$

$$= \frac{1}{n \sum_{i=1}^n (x_i - \bar{x})^2} \begin{bmatrix} (\sum x_i^2 - n\bar{x}x_1)y_1 + \dots + (\sum x_i^2 - n\bar{x}x_n)y_n \\ (-n\bar{x} + nx_1)y_1 + \dots + (-n\bar{x} + nx_n)y_n \end{bmatrix}$$

$$= \frac{1}{n \sum_{i=1}^n (x_i - \bar{x})^2} \begin{bmatrix} n\bar{y} \sum x_i^2 - n\bar{x} \sum x_i y_i \\ -n^2 \bar{x} \bar{y} + n \sum x_i y_i \end{bmatrix}.$$

$$\text{Άρα, για παράδειγμα } \hat{\beta}_1 = \frac{n \sum x_i y_i - n^2 \bar{x} \bar{y}}{n \sum (x_i - \bar{x})^2} = \frac{\sum x_i y_i - n \bar{x} \bar{y}}{\sum (x_i - \bar{x})^2} = \frac{\sum (x_i - \bar{x}) y_i}{\sum (x_i - \bar{x})^2}.$$

#2. Πολλαπλή Γραμμική Παλινδρόμηση

$$y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip} + \varepsilon_i, \quad i = 1, \dots, n.$$

Γνωρίζουμε ότι $SS_{tot} = SS_{reg} + SS_{res}$, όπου

$$SS_{tot} = \sum_{i=1}^n (y_i - \bar{y})^2,$$

$$SS_{reg} = \sum_{i=1}^n (\hat{y}_i - \bar{y}_i)^2,$$

$$SS_{res} = \sum_{i=1}^n (y_i - \hat{y}_i)^2.$$

Θα αποδείξουμε αυτήν την ανάλυση με προβολές.

Μπορώ να γράψω το μοντέλο

$$\underline{y} = \mathbf{X} \underline{\beta} + \underline{\varepsilon} = \underline{\mu} + \underline{\varepsilon}, \quad \underline{\mu} \in V = \text{χώρος που παράγεται από τις στήλες του } \mathbf{X}.$$

Έχω ότι το εκτιμώμενο μοντέλο είναι $\hat{\underline{y}} = \hat{\underline{\mu}} = \begin{pmatrix} \hat{y}_1 \\ \vdots \\ \hat{y}_n \end{pmatrix}$, οπότε

$$SS_{tot} = \|\underline{y} - \bar{y} \cdot \underline{1}\|^2, \quad SS_{reg} = \|\hat{\underline{y}} - \bar{y} \cdot \underline{1}\|^2, \quad SS_{res} = \|\underline{y} - \hat{\underline{y}}\|^2.$$

Αφού V γνήσιος υπόχωρος του \mathfrak{R}^n , έχω ότι $\mathfrak{R}^n = V \oplus V^\perp$.

Αλλά αν $M = \langle \underline{1} \rangle$, τότε $M \subset V$. Επομένως $V = M \oplus V/M$.

Άρα $\mathfrak{R}^n = M \oplus V/M \oplus V^\perp$.

Αν $\underline{y} \in \mathfrak{R}^n \square \underline{y} = \mathbf{P}_M \underline{y} + \mathbf{P}_{V/M} \underline{y} + \mathbf{P}_{V^\perp} \underline{y}$ και οι προβολές είναι ανά δύο ορθογώνιες.

Άρα $\|\underline{y}\|^2 = \|\mathbf{P}_M \underline{y}\|^2 + \|\mathbf{P}_{V/M} \underline{y}\|^2 + \|\mathbf{P}_{V^\perp} \underline{y}\|^2 \quad (\square)$.

Έχω ότι $\mathbf{P}_M \underline{y} = \frac{(\underline{1}^T \cdot \underline{y})}{\underline{1}^T \cdot \underline{1}} \cdot \underline{1} = \bar{y} \cdot \underline{1} \square \|\mathbf{P}_M \underline{y}\|^2 = n\bar{y}^2$.

$$\mathbf{P}_{V/M} \underline{y} = \mathbf{P}_V \underline{y} - \mathbf{P}_M \underline{y} \quad \square \quad \|\mathbf{P}_{V/M} \underline{y}\|^2 = \|\mathbf{P}_V \underline{y} - \mathbf{P}_M \underline{y}\|^2 = \|\hat{\underline{y}} - \bar{y} \cdot \underline{1}\|^2$$

$$\|\mathbf{P}_{V^\perp} \underline{y}\|^2 = \|\underline{y} - \mathbf{P}_V \underline{y}\|^2 = \|\underline{y} - \hat{\underline{\mu}}\|^2 = \|\underline{y} - \hat{\underline{y}}\|^2.$$

$$\text{Apα, } (\square) \quad \square \quad \|\underline{y}\|^2 = n\bar{y}^2 + \|\hat{\underline{y}} - \bar{y} \cdot \underline{1}\|^2 + \|\underline{y} - \hat{\underline{y}}\|^2$$

$$\square \quad \sum_{i=1}^n y_i^2 - n\bar{y}^2 = SS_{reg} + SS_{res}$$

$$\square \quad SS_{tot} = SS_{with} + SS_{res}.$$