

## İST 417 Lineer Modeller – 10. Hafta

### Çoklu Lineer Regresyon Tahmini

Çoklu lineer regresyon modeli

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \cdots + \beta_k x_{ik} + \varepsilon_i, \quad i = 1, 2, \dots, n$$

olarak tanımlanır.

#### **Not:**

$y_i = \beta_0 + \beta_1 x_i^2 + \varepsilon_i \rightarrow$  Bu model parametreye göre lineer

$y_i = \beta_0 + e^{\beta_1 x_i} + \varepsilon_i \rightarrow$  Bu model parametreye göre lineer değil.

#### **Varsayımlar:**

- i.  $E(\varepsilon_i) = 0, i = 1, 2, \dots, n$  ya da  $E(y_i) = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \cdots + \beta_k x_{ik}$
- ii.  $Var(\varepsilon_i) = \sigma^2, i = 1, 2, \dots, n$  ya da  $Var(y_i) = \sigma^2$
- iii.  $Cov(\varepsilon_i, \varepsilon_j) = 0, i \neq j$  ya da  $Cov(y_i, y_j) = 0$

$y_i$  ler

$$y_1 = \beta_0 + \beta_1 x_{11} + \beta_2 x_{12} + \cdots + \beta_k x_{1k} + \varepsilon_1$$

$$y_2 = \beta_0 + \beta_1 x_{21} + \beta_2 x_{22} + \cdots + \beta_k x_{2k} + \varepsilon_2$$

⋮

$$y_n = \beta_0 + \beta_1 x_{n1} + \beta_2 x_{n2} + \cdots + \beta_k x_{nk} + \varepsilon_n$$

olarak yazılabilir.

Bu denklemler aşağıda gösterildiği gibi

$$y = X\beta + \varepsilon$$

şeklinde matris formatında da yazılabilir. Burada,

$$y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}, \quad X = \begin{bmatrix} 1 & x_{11} & x_{12} & x_{1k} \\ 1 & x_{21} & x_{22} & x_{2k} \\ \vdots & \vdots & \vdots & \vdots \\ 1 & x_{n1} & x_{n2} & x_{nk} \end{bmatrix}, \quad \beta = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{bmatrix} \quad \text{ve} \quad \varepsilon = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix}$$

olarak tanımlanır.

Burada,  $\text{rank}(X)=k+1$  dir. Yukarıda verilen 3 varsayım aşağıda gösterildiği gibi 2 varsayım olarak da ifade edilebilir.

- i.  $E(\varepsilon) = 0$  ya da  $E(y) = X\beta$   
 ii.  $Cov(\varepsilon) = \sigma^2 I$  ya da  $Cov(y) = \sigma^2 I$  (ii. ve iii. varsayımlara denk)

$$\sigma^2 I = \sigma^2 \begin{bmatrix} 1 & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & 1 \end{bmatrix} = \begin{bmatrix} \sigma^2 & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & \sigma^2 \end{bmatrix} \rightarrow Var(\varepsilon_i) = \sigma^2 \text{ ve } Cov(\varepsilon_i, \varepsilon_j) = 0 \text{ anlamına}$$

gelir.

### **$\beta$ ve $\sigma^2$ nin Tahmini**

#### **$\beta$ nın EKK Tahmin Edicisi:**

$\beta$  nın EKK tahmin edicisi

$$\sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_{i1} - \beta_2 x_{i2} - \dots - \beta_k x_{ik})^2$$

ifadesinin  $\beta$  parametresine göre türevinin alınıp 0 a eşitlenmesi ile bulunur.

#### **Teorem:**

$$y = X\beta + \varepsilon$$

Modelinde  $X_{n \times (k+1)}$  boyutunda bir matris ve  $\text{rank}(X) = k+1 < n$  (tam ranklı ise)  $\beta$  nın EKK tahmin edicisi

$$\hat{\beta} = (X'X)^{-1}X'y$$

olarak bulunur.

#### **İspat:**

$$\sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (y_i - x_i \hat{\beta})^2 = \varepsilon' \varepsilon = (y - X\hat{\beta})'(y - X\hat{\beta})$$

$X'_i = [1 \ x_{i1} \ x_{i2} \ \dots \ x_{ik}]$ , bir başka deyişle model matrisi X in i. satırıdır.

$$\varepsilon' \varepsilon = y'y - y'X\hat{\beta} - \hat{\beta}'X'y$$

$$\Rightarrow \frac{\partial(\varepsilon' \varepsilon)}{\partial \hat{\beta}} = 0 - 2X'y + 2X'X\hat{\beta} = 0$$

$$2X'X\hat{\beta} = 2X'y \rightarrow \text{Normal denklemler}$$

$$\Rightarrow \hat{\beta} = (X'X)^{-1}X'y \text{ ( X tam ranklı ve X'X non-singular)}$$

Şimdi  $\hat{\beta} = (X'X)^{-1}X'y$  eşitliğini kullanarak  $\hat{\beta}$  yı bulalım.

$$\begin{aligned}
X'X &= \begin{bmatrix} 1 & 1 & \dots & 1 \\ x_{11} & x_{21} & \dots & x_{n1} \\ \vdots & \vdots & \vdots & \vdots \\ x_{1k} & x_{2k} & \dots & x_{nk} \end{bmatrix} \begin{bmatrix} 1 & x_{11} & x_{12} & x_{1k} \\ 1 & x_{21} & x_{22} & x_{2k} \\ \vdots & \vdots & \vdots & \vdots \\ 1 & x_{n1} & x_{n2} & x_{nk} \end{bmatrix} \\
&= \begin{bmatrix} n & \sum x_{i1} & \sum x_{i2} & \dots & \sum x_{ik} \\ \sum x_{i1}^2 & \sum x_{i1}x_{i2} & \dots & \sum x_{i1}x_{ik} \\ \sum x_{i2}^2 & \dots & \sum x_{i2}x_{ik} \\ \vdots & \vdots & \vdots \\ \sum x_{ik}^2 \end{bmatrix} \\
X'y &= \begin{bmatrix} 1 & 1 & \dots & 1 \\ x_{11} & x_{21} & \dots & x_{n1} \\ \vdots & \vdots & \vdots & \vdots \\ x_{1k} & x_{2k} & \dots & x_{nk} \end{bmatrix} \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} = \begin{bmatrix} \sum y_i \\ \sum x_{i1}y_i \\ \vdots \\ \sum x_{ik}y_i \end{bmatrix}
\end{aligned}$$

Kolaylık olması bakımından bu örneği k=1 (Basit Doğrusal Regresyon) modeli için çözelim.

k=1 için

$$X'X = \begin{bmatrix} n & \sum x_i \\ \sum x_i & \sum x_i^2 \end{bmatrix} \quad X'y = \begin{bmatrix} \sum y_i \\ \sum x_i y_i \end{bmatrix} \quad X = \begin{bmatrix} 1 & x_1 \\ \vdots & \vdots \\ 1 & x_n \end{bmatrix} \quad \beta = \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix}$$

olur. Buradan,

$$(X'X)^{-1} = \frac{1}{n \sum x_i^2 - (\sum x_i)^2} \begin{bmatrix} \sum x_i^2 & -\sum x_i \\ -\sum x_i & n \end{bmatrix}$$

$$\hat{\beta} = (X'X)^{-1}X'y = \frac{1}{n \sum x_i^2 - (\sum x_i)^2} \begin{bmatrix} \sum x_i^2 & -\sum x_i \\ -\sum x_i & n \end{bmatrix} \begin{bmatrix} \sum y_i \\ \sum x_i y_i \end{bmatrix}$$

$$= \frac{1}{n \sum x_i^2 - (\sum x_i)^2} \begin{bmatrix} \sum x_i^2 (\sum y_i) - (\sum x_i)(\sum x_i y_i) \\ -(\sum x_i)(\sum y_i) + n \sum x_i y_i \end{bmatrix}$$

$$\hat{\beta}_0 = \frac{\sum x_i^2 (\sum y_i) - (\sum x_i)(\sum x_i y_i)}{n \sum x_i^2 - (\sum x_i)^2} = \frac{\sum x_i^2 n \bar{y} - n \bar{x} \sum x_i y_i}{n \sum x_i^2 - n^2 \bar{x}^2} = \frac{\sum x_i^2 \bar{y} - \sum x_i y_i \bar{x}}{\sum x_i^2 - n \bar{x}^2}$$

$$\hat{\beta}_1 = \frac{-\sum x_i (\sum y_i) + n \sum x_i y_i}{n \sum x_i^2 - (\sum x_i)^2} = \frac{n \sum x_i y_i - n^2 \bar{x} \bar{y}}{n \sum x_i^2 - n^2 \bar{x}^2} = \frac{\sum x_i y_i - n \bar{x} \bar{y}}{\sum x_i^2 - n \bar{x}^2}$$

bulunur.

Aşağıdaki teoremlerde  $X$  matrisinin sabitlerden oluşan ve tam ranklı olduğu varsayılmıştır.

**Teorem:**  $E(y) = X\beta \Rightarrow \hat{\beta}, \beta$  parametresinin yansız bir tahmin edicisidir.

**İspat:**  $E(\hat{\beta}) = E((X'X)^{-1}X'y) = (X'X)^{-1}X'E(y) = (X'X)^{-1}X'X\beta = \beta$

dir. Dolayısıyla,  $\hat{\beta}, \beta$  parametresinin yansız bir tahmin edicisidir.

**Teorem:**  $Cov(y) = \sigma^2 I$  ise  $Cov(\hat{\beta}) = \sigma^2 (X'X)^{-1}$

**İspat:**  $Cov(\hat{\beta}) = Cov((X'X)^{-1}X'y) = (X'X)^{-1}X'Cov(y)((X'X)^{-1}X')'$   
 $= (X'X)^{-1}X'((X'X)^{-1}X')'\sigma^2 = (X'X)^{-1}X'X(X'X)^{-1}\sigma^2 = (X'X)^{-1}\sigma^2$

**Örnek:** Basit doğrusal regresyon modeli için  $Var(\hat{\beta}_0), Var(\hat{\beta}_1)$  ve  $Cov(\hat{\beta}_0, \hat{\beta}_1)$  yı bulunuz.

$$Cov(\hat{\beta}) = (X'X)^{-1}\sigma^2$$

Bir önceki örnekten

$$(X'X)^{-1} = \frac{1}{n\sum x_i^2 - (\sum x_i)^2} \begin{bmatrix} \sum x_i^2 & -\sum x_i \\ -\sum x_i & n \end{bmatrix}$$

olarak bulunmuştu. Bu nedenle

$$Cov(\hat{\beta}) = \frac{\sigma^2}{n\sum x_i^2 - (\sum x_i)^2} \begin{bmatrix} \sum x_i^2 & -\sum x_i \\ -\sum x_i & n \end{bmatrix}$$

bulunur. Buradan

$$Cov(\hat{\beta}) = Cov \begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \end{bmatrix} = \begin{bmatrix} Var(\hat{\beta}_0) & Cov(\hat{\beta}_0, \hat{\beta}_1) \\ Cov(\hat{\beta}_0, \hat{\beta}_1) & Var(\hat{\beta}_1) \end{bmatrix}$$

olarak ifade edildiğinden

$$Var(\hat{\beta}_0) = \frac{\sum x_i^2}{n\sum x_i^2 - (\sum x_i)^2} \sigma^2, \quad Var(\hat{\beta}_1) = \frac{n}{n\sum x_i^2 - (\sum x_i)^2} \sigma^2 \quad \text{ve} \quad Cov(\hat{\beta}_0, \hat{\beta}_1) = -\frac{\sum x_i}{n\sum x_i^2 - (\sum x_i)^2} \sigma^2$$

bulunur.