

## En Küçük Kareler Kestiricilerinin Özellikleri ve Uydurulan Regresyon Modeli

Denklem (1.6) ve (1.7)'den  $\hat{\beta}_0$  ve  $\hat{\beta}_1$ 'nin  $y_i$  gözlemlerinin **doğrusal birleşimleri** olduğu görülmektedir.

$$\hat{\beta}_1 = \frac{S_{xy}}{S_{xx}} = \sum_{i=1}^n c_i y_i \quad , \quad i = 1, 2, \dots, n \quad , \quad c_i = \frac{(x_i - \bar{x})}{S_{xx}}$$

olarak yazılabilir.

- $\hat{\beta}_0$  ve  $\hat{\beta}_1$ , en küçük kareler kestiricileri,  $\beta_0$  ve  $\beta_1$  model parametrelerinin **yansız** kestiricileridir.

$E(\varepsilon_i) = 0$  olarak varsayıldığından,

$$\begin{aligned} E(\hat{\beta}_1) &= E\left(\sum_{i=1}^n c_i y_i\right) = \sum_{i=1}^n c_i E(y_i) \\ &= \sum_{i=1}^n c_i (\beta_0 + \beta_1 x_i) = \beta_0 \sum_{i=1}^n c_i + \beta_1 \sum_{i=1}^n c_i x_i \end{aligned}$$

Burada,  $\sum_{i=1}^n c_i = \sum_{i=1}^n \frac{(x_i - \bar{x})}{S_{xx}} = 0$  ve  $\sum_{i=1}^n c_i x_i = \sum_{i=1}^n \frac{(x_i - \bar{x})x_i}{S_{xx}} = 1$  olduğundan ;

$$E(\hat{\beta}_1) = \beta_1$$

olur. Diğer bir deyişle, eğer modelin doğru olduğu ( $E(y_i) = \beta_0 + \beta_1 x_i$ ) kabul edilirse o zaman  $\hat{\beta}_1$ ,  $\beta_1$ 'in **yansız** kestiricisidir.

$$\begin{aligned} E(\hat{\beta}_0) &= E\left(\sum_{i=1}^n d_i y_i\right) = \sum_{i=1}^n d_i E(y_i) \\ &= \sum_{i=1}^n d_i (\beta_0 + \beta_1 x_i) = \beta_0 \sum_{i=1}^n d_i + \beta_1 \sum_{i=1}^n d_i x_i \end{aligned}$$

Burada  $\sum_{i=1}^n d_i = \sum_{i=1}^n \left(\frac{1}{n} - \frac{(x_i - \bar{x})\bar{x}}{S_{xx}}\right) = 1$  ve  $\sum_{i=1}^n d_i x_i = \sum_{i=1}^n \left[\frac{1}{n} - \frac{(x_i - \bar{x})\bar{x}}{S_{xx}}\right] x_i = 0$

olduğundan;

$$E(\hat{\beta}_0) = \beta_0$$

olur.

Eğer modelin doğru olduğu ( $E(y_i) = \beta_0 + \beta_1 x_i$ ) kabul edilirse bu durumda  $\hat{\beta}_0$ ,  $\beta_0$ 'in **yansız** kestiricisidir.

➤  $\hat{\beta}_1$ 'nin varyansı,

$$Var(\hat{\beta}_1) = Var\left(\sum_{i=1}^n c_i y_i\right) = \sum_{i=1}^n c_i^2 Var(y_i) \quad (1.13)$$

$y_i$  gözlemleri ilişkisiz olduğundan toplamın varyansı, sadece varyansların toplamıdır.

$Var(y_i) = \sigma^2$  olup,

$$Var(\hat{\beta}_1) = \sigma^2 \sum_{i=1}^n c_i^2 = \frac{\sigma^2 \sum_{i=1}^n (x_i - \bar{x})^2}{S_{xx}^2} = \frac{\sigma^2}{S_{xx}} \quad (1.14)$$

$\hat{\beta}_0$ 'nin varyansı,

$$\begin{aligned} Var(\hat{\beta}_0) &= Var(\bar{y} - \hat{\beta}_1 \bar{x}) \\ &= Var(\bar{y}) + \bar{x}^2 Var(\hat{\beta}_1) - 2 \bar{x} Cov(\bar{y}, \hat{\beta}_1) \end{aligned}$$

$Var(\bar{y}) = \frac{\sigma^2}{n}$  ve  $Cov(\bar{y}, \hat{\beta}_1) = 0$  olup,

$$Var(\hat{\beta}_0) = Var(\bar{y}) + \bar{x}^2 Var(\hat{\beta}_1) = \sigma^2 \left( \frac{1}{n} + \frac{\bar{x}^2}{S_{xx}} \right) \quad (1.15)$$

olur.

## • GAUSS-MARKOV TEOREMİ

$E(\varepsilon) = 0$  ,  $Var(\varepsilon) = \sigma^2$  varsayımına ve ilişkisiz hatalara sahip (1.1) denklemindeki regresyon modeli için en küçük kareler kestiricilerinin,  $y_i$ 'nin **doğrusal** birleşimleri olan

diğer bütün yansız kestiricilerle karşılaştırıldığında **yansız** olduklarını ve **minimum varyansa** sahip olduklarını belirten bir teoremdir.

Bu teorem, en küçük kareler kestiricilerinin "**en iyi doğrusal yansız kestiriciler (Best Linear Unbiased Estimator, BLUE)**" olduğunu kanıtlamaktadır.

❖ **En küçük kareler uyumunun daha başka yararlı özellikleri de vardır :**

1)  $\beta_0$  kesim noktasını içeren herhangi bir regresyon modelindeki artıkların toplamı her zaman sıfırdır. (Yuvarlama hataları toplamı etkileyebilir.)

$$\sum_{i=1}^n (y_i - \hat{y}_i) = \sum_{i=1}^n e_i = 0$$

2)  $y_i$  gözlenen değerlerinin toplamı,  $\hat{y}_i$  değerlerinin toplamına eşittir :

$$\sum_{i=1}^n y_i = \sum_{i=1}^n \hat{y}_i$$

3) En küçük kareler regresyon doğrusu her zaman verilerin **merkezinden**  $[(\bar{y}, \bar{x}) \text{ noktası}]$  geçer.

4) Bağımsız değişkenin karşılık gelen değeriyle ağırlıklandırılmış artıkların toplamı her zaman sıfırdır :

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

5)  $\hat{y}_i$  kestirim değerleri ile ağırlıklandırılmış artıkların toplamı her zaman sıfırdır.

$$\sum_{i=1}^n \hat{y}_i e_i = 0$$