

6.1 Klasik Doğrusal Regresyon Modelinin Varsayımlarının Matrisle Gösterilmesi

1. Hata terimlerinin beklenen değeri sıfırdır ($E(u_i) = 0$) varsayımın matrisle gösterimi $E(\mathbf{u}) = \mathbf{0}$ şeklindedir.

$$E \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix} = \begin{bmatrix} E(u_1) \\ E(u_2) \\ \vdots \\ E(u_n) \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \text{ anlamına gelmektedir.}$$

2. Hata terimlerinin varyansı sabittir ve aralarındaki kovaryans sıfırdır ($E(u_i u_j) = 0$, $i \neq j$ ve $E(u_i u_j) = \sigma^2$, $i = j$ iken) varsayımın matrisle gösterimi $E(\mathbf{u}\mathbf{u}') = \sigma^2 \mathbf{I}$ dir.

$$E(\mathbf{u}\mathbf{u}') = E \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix} \begin{bmatrix} u_1 & u_2 & \dots & u_n \end{bmatrix} = E \begin{bmatrix} u_1^2 & u_1 u_2 & \dots & u_1 u_n \\ u_2 u_1 & u_2^2 & \dots & u_2 u_n \\ \vdots & \vdots & \ddots & \vdots \\ u_n u_1 & u_n u_2 & \dots & u_n^2 \end{bmatrix}$$
$$= \begin{bmatrix} E(u_1^2) & E(u_1 u_2) & \dots & E(u_1 u_n) \\ E(u_2 u_1) & E(u_2^2) & \dots & E(u_2 u_n) \\ \vdots & \vdots & \ddots & \vdots \\ E(u_n u_1) & E(u_n u_2) & \dots & E(u_n^2) \end{bmatrix}$$

$E(u_i) = 0$ olduğundan $\text{Var}(u_i) = E\{u_i - E(u_i)\}^2 = E\{u_i\}^2$ ve

$\text{Cov}(u_i u_j) = E\{[u_i - E(u_i)][u_j - E(u_j)]\} = E\{u_i u_j\}$. Dolayısıyla,

$$E(\mathbf{u}\mathbf{u}') = \begin{bmatrix} \text{Var}(u_1^2) & \text{Cov}(u_1 u_2) & \dots & \text{Cov}(u_1 u_n) \\ \text{Cov}(u_2 u_1) & \text{Var}(u_2^2) & \dots & \text{Cov}(u_2 u_n) \\ \vdots & \vdots & \ddots & \vdots \\ \text{Cov}(u_n u_1) & \text{Cov}(u_n u_2) & \dots & \text{Var}(u_n^2) \end{bmatrix}$$
$$= \begin{bmatrix} \sigma^2 & 0 & \dots & 0 \\ 0 & \sigma^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma^2 \end{bmatrix} = \sigma^2 \begin{bmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 1 \end{bmatrix} = \sigma^2 \mathbf{I} \text{ olmaktadır.}$$

Bu matris hata terimlerinin varyans-kovaryans matrisidir. Ana köşegen üzerindeki öğeler varyansı, diğer öğeler kovaryansı gösterir. Simetrik matristir.

$E(\mathbf{u}\mathbf{u}') = \sigma^2\mathbf{I}$ varsayımı iki alt varsayım içerir.

2.i Sabit varyans (homoscedasticity) veya değişmeyen varyans varsayımı:

Hata terimlerinin varyansı sabittir ve aynıdır. $\text{Var}(u_i) = \sigma^2$

Bu varsayım sağlanmadığında *değişen varyans* (heteroscedasticity) sorunu vardır.

2.ii Ardışık bağımlılık (autocorrelation) yok varsayımı: Hata terimleri arasındaki

kovaryans sıfırdır. $\text{Cov}(u_i, u_j) = 0$ $i, j = 1, \dots, n$ $i \neq j$

Bu varsayım sağlanmadığında *ardışık bağımlılık sorunu* ortaya çıkar.

2i varsayımı ile Y_i 'lerin varyansları da belirlenmiş olmaktadır. Vektör olarak ifade edersek

$$\text{Var}(\mathbf{Y}) = E\{[\mathbf{Y} - E(\mathbf{Y})][\mathbf{Y} - E(\mathbf{Y})]'\} = E\{[\mathbf{Y} - \mathbf{X}\boldsymbol{\beta}][\mathbf{Y} - \mathbf{X}\boldsymbol{\beta}]'\}$$

$$= E\{[\mathbf{X}\boldsymbol{\beta} + \mathbf{u} - \mathbf{X}\boldsymbol{\beta}][\mathbf{X}\boldsymbol{\beta} + \mathbf{u} - \mathbf{X}\boldsymbol{\beta}]'\} = E\{\mathbf{u}\mathbf{u}'\} = \sigma_u^2\mathbf{I}$$

Bu $\text{Var}(Y_i) = \sigma_u^2$ anlamına gelmektedir.

3. X matrisindeki açıklayıcı değişkenler rassal değişkenler olmayıp her örnekleme aynı değeri alan değişkenlerdir. Bu durumda X değişkenleri ile hata terimleri arasında bir ilişki de olamaz. Açıklayıcı değişkenlerin rassal değişkenler olması kabul edilirse, bu durumda X'ler ile u'nun ilişkisiz olduğunu açıkça varsaymak gerekir. Her iki durumda da varsayım şu şekildedir: $\text{Cov}(X_{ij}, u_i) = 0$ veya matris ifadesiyle $E(\mathbf{X}\mathbf{u}) = 0$

4. X matrisinin aşaması (rank) denklemde tahmin edilen katsayı adedi k'ya eşittir ve k da veri sayısı n'den küçüktür: $\text{rank}(\mathbf{X}) = k < n$

$\text{rank}(\mathbf{X}) = k$ olması, X verilerini temsil eden vektörlerin birbirinden bağımsız olması anlamına gelmektedir. Bu varsayım sağlanmadığında *tam çoklu doğrusallık* (perfect multicollinearity) sorunu var demektir.

$k < n$ sınırlaması, *serbestlik derecesi* (degrees of freedom) üzerine bir sınırlama getirmektedir. Tahmin sonuçlarının serbestlik derecesi bakımından güvenilir olabilmesi için SD en az 12 olmalıdır.

5. Hata terimleri normal dağılıma sahiptir. Birinci ve ikinci varsayımların geçerli olduğu kabul edilirse, varsayım şu şekildedir: $\mathbf{u} \sim N(0, \sigma^2\mathbf{I})$

Bu varsayım t ve F-testi gibi hipotez testlerinin uygulanmasında gereklidir.

6.2 EKK tahmini

Genel Doğrusal Model

$Y_i = \beta_1 + \beta_2 X_{i2} + \beta_3 X_{i3} + \dots + \beta_k X_{ik} + u_i$, $i = 1 \dots n$ veya $\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{u}$ modelinde EKK

yöntemi $\hat{\mathbf{u}}'\hat{\mathbf{u}} = [\hat{u}_1 \quad \hat{u}_2 \quad \dots \quad \hat{u}_n] \begin{bmatrix} \hat{u}_1 \\ \hat{u}_2 \\ \vdots \\ \hat{u}_n \end{bmatrix} = \hat{u}_1^2 + \hat{u}_2^2 + \dots + \hat{u}_n^2 = \sum_{i=1}^n \hat{u}_i^2$ yi minimize eder.

$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{u}$ ilişkisinden $\hat{\mathbf{u}} = \mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}}$, $\hat{\mathbf{u}}' = (\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}})'$ ve böylece

$\hat{\mathbf{u}}'\hat{\mathbf{u}} = (\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}})'(\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}}) = \mathbf{Y}'\mathbf{Y} - 2\hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{Y} + \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{X}\hat{\boldsymbol{\beta}}$ bulunur.

Minimizasyon için bu fonksiyonun $\hat{\boldsymbol{\beta}}$ ya göre türevi sıfıra eşitlenmelidir:

$$\frac{\partial \hat{\mathbf{u}}'\hat{\mathbf{u}}}{\partial \hat{\boldsymbol{\beta}}} = -2\mathbf{X}'\mathbf{Y} + 2\mathbf{X}'\mathbf{X}\hat{\boldsymbol{\beta}} = \mathbf{0}$$

ve bunun sonucu

$\mathbf{X}'\mathbf{X}\hat{\boldsymbol{\beta}} = \mathbf{X}'\mathbf{Y}$ bulunur.

Son işlemlerin yapılmasında matris cebiri kullanılmıştır. Buradan $\hat{\boldsymbol{\beta}}$ yı bulmak için eşitliğin iki tarafını da $\mathbf{X}'\mathbf{X}$ matrisinin tersiyle çarpmalıyız. Böylece $(\mathbf{X}'\mathbf{X})^{-1}(\mathbf{X}'\mathbf{X})\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}$ ve

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}$$

bulunur. Bu EKK tahmin edicisidir.

6.3 $\hat{\beta}$ nin Varyans-Kovaryans Matrisi ve σ_u^2 'nin tahmini

$$\hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'(\mathbf{X}\beta + \mathbf{u}) = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{X}\beta + (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{u} = \beta + (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{u} \quad (6.1)$$

ve böylece

$$E(\hat{\beta}) = E\{\beta + (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{u}\} = E(\beta) + (\mathbf{X}'\mathbf{X})^{-1}E(\mathbf{X}'\mathbf{u}) = \beta \text{ dir.} \quad (6.2)$$

Burada üçüncü varsayımdan yararlanılmış ve açıklayıcı değişkenlerin rassal olmayıp, her örneklemede aynı değeri aldığı varsayımıyla X 'ler beklenen değerlerin dışına çıkartılmıştır. Buradan katsayı tahminlerinin varyans-kovaryans tahminleri aşağıdaki gibi bulunabilir.

$$\begin{aligned} \text{Var, Cov}(\hat{\beta}) &= E\{[\hat{\beta} - E(\hat{\beta})][\hat{\beta} - E(\hat{\beta})]'\} \\ &= E\{[(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{u}][(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{u}]'\} \quad (\text{çünkü 6.1 ve 6.2'den } \hat{\beta} - E(\hat{\beta}) = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{u}) \\ &= E\{(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{u}\mathbf{u}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'E(\mathbf{u}\mathbf{u}')\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \\ &= (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\sigma_u^2\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \quad (\text{çünkü } E(\mathbf{u}\mathbf{u}') = \sigma_u^2\mathbf{I}) \\ &= \sigma_u^2(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \\ &= \sigma_u^2(\mathbf{X}'\mathbf{X})^{-1} \quad (\text{çünkü } \mathbf{X}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} = \mathbf{I}) \end{aligned}$$

$$(\mathbf{X}'\mathbf{X})^{-1} = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1k} \\ a_{21} & a_{22} & \dots & a_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ a_{k1} & a_{k1} & \dots & a_{kk} \end{bmatrix} \text{ böylece } \text{Var, Cov}(\hat{\beta}) = \begin{bmatrix} \sigma_u^2 a_{11} & \sigma_u^2 a_{12} & \dots & \sigma_u^2 a_{1k} \\ \sigma_u^2 a_{21} & \sigma_u^2 a_{22} & \dots & \sigma_u^2 a_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_u^2 a_{k1} & \sigma_u^2 a_{k1} & \dots & \sigma_u^2 a_{kk} \end{bmatrix}$$

Bu matrisin asal köşegenindeki öğeler $\hat{\beta}_j$ katsayılarının varyanslarıdır.

$$\text{Var}(\hat{\beta}_1) = \sigma_u^2 a_{11}, \text{Var}(\hat{\beta}_2) = \sigma_u^2 a_{22}, \dots \text{Var}(\hat{\beta}_k) = \sigma_u^2 a_{kk},$$

Diğer öğeler $\hat{\beta}_j$ katsayıları arasındaki kovaryansları gösterir. $(\mathbf{X}'\mathbf{X})^{-1}$ simetrik olduğundan karşılık gelen kovaryanslar eşittir.

$$\text{Cov}(\hat{\beta}_1, \hat{\beta}_2) = \sigma_u^2 a_{12} = \sigma_u^2 a_{21} \dots \text{ gibi.}$$

Varyans ve kovaryansların örnek verilerinden tahmin edilebilmesi için σ_u^2 'nin tahmin edilmesi gerekir.

Hata terimi için örnekleme varyansı

$$\text{Var}(\hat{u}_i) = \hat{\sigma}^2 = \frac{\sum \hat{u}_i^2}{n-k} = \frac{\hat{\mathbf{u}}' \hat{\mathbf{u}}}{n-k}$$

Eğer hata terimleri tek tek bulunmak istenmiyorsa $\hat{\mathbf{u}}' \hat{\mathbf{u}}$ toplamı şu şekilde bulunur:

$$\hat{\mathbf{u}}' \hat{\mathbf{u}} = (\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}})'(\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}}) = \mathbf{Y}'\mathbf{Y} - \mathbf{Y}'\mathbf{X}\hat{\boldsymbol{\beta}} - \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{Y} + \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{X}\hat{\boldsymbol{\beta}}$$

$$(\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} \text{ olduğundan } \hat{\boldsymbol{\beta}}' = \mathbf{Y}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1})$$

$$= \mathbf{Y}'\mathbf{Y} - \mathbf{Y}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} - \mathbf{Y}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} + \mathbf{Y}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}$$

$$= \mathbf{Y}'\mathbf{Y} - \mathbf{Y}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} - \mathbf{Y}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} + \mathbf{Y}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}$$

$$= \mathbf{Y}'\mathbf{Y} - \mathbf{Y}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}$$

$$= \mathbf{Y}'\mathbf{Y} - \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{Y}$$

Demek ki

$$\hat{\sigma}_u^2 = \frac{\mathbf{Y}'\mathbf{Y} - \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{Y}}{n-k}$$

6.4 Belirlilik Katsayısının ve F İstatistiğinin Matrislerle Gösterimi

Belirlilik katsayısı matrisler kullanılarak

$$R^2 = \frac{\hat{\beta}'\mathbf{X}'\mathbf{Y} - n\bar{Y}^2}{\mathbf{Y}'\mathbf{Y} - n\bar{Y}^2}$$

formülüyle bulunabilir. Benzer bir şekilde F istatistiğinin formülü aşağıdaki gibidir.

$$F = \frac{R^2/(k-1)}{(1-R^2)/(n-k)}$$

$$F = \frac{(\hat{\beta}'\mathbf{X}'\mathbf{Y} - n\bar{Y}^2)/(k-1)}{(\mathbf{Y}'\mathbf{Y} - \hat{\beta}'\mathbf{X}'\mathbf{Y})/(n-k)}$$