

## HAFTA 9

### Düzeltilici önlemler:

Değişen varyans EKK tahmin edicilerinin sapmasızlık (yansızlık), tutarlılık özelliklerini bozmaz ama bu tahmin ediciler asimptotik (yani büyük örneklerde bile) olarak artık etkin değildirler. Etkinlik yoksunluğu bilinen önsav sınaması işlemlerini kuşkulu duruma sokar. Bu durumda düzeltilici önlemlerin gerekli olduğu açıktır. Düzeltme yapmak için iki düzeltme yaklaşımı

- $\sigma_i^2$  bilindiği
- $\sigma_i^2$  bilinmediği

durumlardır.

### I. $\sigma_i^2$ biliniyorsa:

$\sigma_i^2$  biliniyorsa, değişen varyansı düzeltmenin en kolay yolu ağırlıklandırılmış en küçük kareler yöntemidir. Bu yöntemle bulunan en küçük kareler tahmin edicileri BLUE (DESTE) dur.

**Örnek:**  $Y$  = çalışan kişi başına yapılan ortalama ödeme (\$)

$$X = \begin{matrix} \text{çalışan} & \text{kişi} & \text{başına} & \text{işyeri} & \text{büyüklüğü} \end{matrix} = \begin{cases} 1-4 \text{ çalışan} & \Rightarrow 1 \\ 5-9 \text{ çalışan} & \Rightarrow 2 \\ \vdots & \Rightarrow \vdots \\ 1000-2499 \text{ çalışan} & \Rightarrow 9 \end{cases}$$

ile ölçülmüştür.

$\sigma_i$  = ücretlerin standart sapmaları

$Y_i$	$X_i$	$\sigma_i$	$Y_i/\sigma_i$	$X_i/\sigma_i$
3396	1	743.7	4.5664	0.0013
3787	2	851.4	4.4480	0.0023
4013	3	727.8	5.5139	0.0041
4104	4	805.06	5.0978	0.0050
4146	5	929.9	4.4585	0.0054
4241	6	1080.6	8.9247	0.0055
4387	7	1243.2	3.5288	0.0056
4538	8	1307.7	3.4702	0.0061
4843	9	1112.5	4.3532	0.0081

Model:  $Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i; \quad i = 1, 2, \dots, 9$

$$\frac{Y_i}{\sigma_i} = \beta_0 \left( \frac{1}{\sigma_i} \right) + \beta_1 \left( \frac{X_i}{\sigma_i} \right) + \left( \frac{\varepsilon_i}{\sigma_i} \right)$$

$$Y_i^* = \underbrace{\beta_0^*}_{\beta_0^*} X_i^* + \varepsilon_i^*$$

Ağırlıklandırılmış en küçük kareler kestirim modeli:

$$\hat{Y}_i^* = \hat{\beta}_0 (1/\sigma_i) + \hat{\beta}_1 X_i^*$$

$$= 3406.639 (1/\sigma_i) + 154.153 X_i^*$$

Std. hata: 80.983 16.959

$t$  42.066 9.090

$$R^2 = 0.9993$$

Ağırlıklandırılmadan bulunan en küçük kareler kestirim modeli:

$$\hat{Y}_i^* = \hat{\beta}_0 + \hat{\beta}_1 X_i^*$$

$$= 3417.833 + 148.767 X_i^*$$

Std. hata: 81.136 14.418

$t$  42.125 10.318

$$R^2 = 0.9383$$

Görüleceği üzere  $\hat{\beta}_0$  ve  $\hat{\beta}_1$  her iki model için farklıdır. Ağırlıklandırılmış modelde açıklayıcı değişkenler  $1/\sigma_i$  ve  $X_i/\sigma_i$  olarak iki değişkenli orijinden geçen regresyon modeli tahmin edilir.

## II. $\sigma_i^2$ bilinmiyorsa:

$\sigma_i^2$  bilinmiyorsa BLUE tahmin edicilerini bulmak için ağırlıklandırılmış en küçük kareler yöntemi kullanılabilir. Gerçek  $\sigma_i^2$  bilinmediği durumda değişen varyans varken bile EKK tahmin edicileri varyanslarının tutarlı tahminleri bulunabilir.

### Değişen varyansla tutarlı White varyansları ve standart hataları:

White bu tutarlı tahmin edicileri asimptotik olarak geçerli istatistik çıkarımlar yapılabilecek biçimde gerçekleştirilebileceğini göstermiştir. Bazı bilgisayar yazılımları EKK tahmin edicilerinin varyansları, standart hataları yanı sıra tutarlı White varyansları ve standart hatalarını da vermektedir.

Örnek: White sürecinin gösterimi:

William H. Greene'nin Econometric Analysis kitabından alına bir örnek

$Y$  = 1979 yılında eyaletlere göre kamu okullarına kişi başına yapılan harcama

$X = 1979$  yılında eyaletlere göre kişi başına gelir

Veriler Amerika'daki 50 eyaleti ve Washington D.C.'yi içerir.

Kestirim modeli:

$$Y_i = 832.91 - 1834.2(\text{Gelir}) + 1587.04(\text{Gelir})^2$$

$$S_{\hat{\beta}} : 327.3 \quad 829.01 \quad 519.10$$

$$t : 2.54 \quad 2.21 \quad 3.06$$

$$\text{White } S_{\hat{\beta}} : 460.9 \quad 1243.0 \quad 830.0$$

$$t : 1.81 \quad -1.48 \quad 1.91$$

Yorum: Yukarıdaki sonuçlara bakılırsa White değişen varyansa göre düzeltilmiş standart hataların EKK standart hatalarından daha büyüktür. Dolayısıyla tahmin edilen test istatistikleri EKK ile bulunan  $t$  - değerlerinden daha küçüktür. White ve EKK ile veri kümesinde değişen varyansın ciddi bir soru olup olmadığına bakılabilir. %5 anlam düzeyinde EKK'ya göre her iki açıklayıcı değişken istatistiksel anlamlı iken White tahmin edicilerine göre istatistiksel anlamlı değildir.

#### **Değişen varyansın yapısına ilişkin akla uygun varsayımlar:**


White sürecinin büyük örneklem süreci olmasının yanı sıra bir başka sakıncası da tahmin edicilerinin veri dönüşüm yöntemleriyle elde edilen tahmin ediciler kadar etkin olamamasıdır. Bunu açıklamak için

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i$$

basit doğrusal modeli ele alınırsa, değişen varyansa ilişkin varsayımlar:

1. Hata varyansı  $X_i^2$  ile doğru orantılıdır.

$$\text{Var}(\varepsilon_i) = \sigma^2 X_i^2$$



$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i$$


$$\frac{Y_i}{X_i} = \beta_0 \frac{1}{X_i} + \beta_1 + \frac{\varepsilon_i}{X_i} \Rightarrow Y_i^* = \beta_0 \frac{1}{X_i} + \beta_1 + \varepsilon_i^*$$

$$\text{Var}(\varepsilon_i^*) = \text{Var}\left(\frac{\varepsilon_i}{X_i}\right) = \frac{1}{X_i^2} \text{Var}(\varepsilon_i) = \frac{1}{X_i^2} \sigma^2 X_i^2 = \sigma^2 \text{ sabitlenir.}$$

$\varepsilon_i^*$  sabit varyanslı hata terimleri  $\frac{Y_i}{X_i}$  ile  $\frac{1}{X_i}$  arasındaki regresyon modeli bulunur.

2. Karekök dönüştürmesi: Hata varyansı  $X_i$  ile doğru orantılıdır.

$$\text{Var}(\varepsilon_i) = \sigma^2 X_i$$



$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i$$

$$\frac{Y_i}{\sqrt{X_i}} = \beta_0 \frac{1}{\sqrt{X_i}} + \beta_1 \frac{X_i}{\sqrt{X_i}} + \frac{\varepsilon_i}{\sqrt{X_i}} \Rightarrow Y_i^* = \beta_0 \frac{1}{\sqrt{X_i}} + \beta_1 \sqrt{X_i} + \varepsilon_i^*$$

Burada  $\varepsilon_i^* = \frac{\varepsilon_i}{\sqrt{X_i}}$  ve  $X_i > 0$ 'dır.

$$\text{Var}(\varepsilon_i^*) = \text{Var}\left(\frac{\varepsilon_i}{\sqrt{X_i}}\right) = \frac{1}{X_i} \text{Var}(\varepsilon_i) = \frac{1}{X_i} \sigma^2 X_i = \sigma^2 \text{ sabitlenir.}$$

Burada  $\varepsilon_i^*$  sabit varyanslı hata terimleri  $\frac{Y_i}{\sqrt{X_i}}$ ,  $\frac{1}{\sqrt{X_i}}$  ve  $\sqrt{X_i}$  arasındaki orijinden geçen regresyon modeli ile bulunur.

3. Hata varyansı  $Y_i$ 'nin ortalama değerinin karesiyle doğru orantılıdır.

$$\text{Var}(\varepsilon_i) = \sigma^2 \{E(Y_i)\}^2 \text{ ve } E(Y_i) = \beta_0 + \beta_1 X_i$$

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i$$

$$\frac{Y_i}{E(Y_i)} = \beta_0 \frac{1}{E(Y_i)} + \beta_1 \frac{X_i}{E(Y_i)} + \frac{\varepsilon_i}{E(Y_i)} \Rightarrow Y_i^* = \beta_0 \frac{1}{E(Y_i)} + \beta_1 X_i^* + \varepsilon_i^*$$

$$\text{Var}(\varepsilon_i^*) = \text{Var}\left(\frac{\varepsilon_i}{E(Y_i)}\right) = \frac{1}{\{E(Y_i)\}^2} \text{Var}(\varepsilon_i) = \frac{1}{\{E(Y_i)\}^2} \sigma^2 \{E(Y_i)\}^2 = \sigma^2 \text{ sabitlenir.}$$

Burada  $E(Y_i)$  bilinmediği için bu dönüşüm uygulanabilir değildir.  $E(Y_i)$ 'nin bir tahmin edicisi  $\hat{Y}_i$  olduğuna göre  $Y_i$ 'nin  $X_i$  üzerine kestirim modeli bulunarak  $\hat{Y}_i$  elde edilir. Sonra bu dönüşüm

$$\frac{Y_i}{\hat{Y}_i} = \beta_0 \frac{1}{\hat{Y}_i} + \beta_1 \frac{X_i}{\hat{Y}_i} + \frac{\varepsilon_i}{\hat{Y}_i}$$

$$Y_i^* = X_i^* \varepsilon_i^*$$

uygulanır.  $\hat{Y}_i$ 'lar her ne kadar  $E(Y_i)$ 'ye tam tamına eşit olmasa da tutarlı tahmin edicilerdir. Sonuç olarak

$$\hat{Y}_i \xrightarrow{n \rightarrow \infty} E(Y_i)$$

olacağından, eğer örneklem yeterince büyük kabul edilirse uygulamada bu dönüşüm yeterince başarılı olur.

4. Log dönüştürmesi:

$$\ln Y_i = \beta_0 + \beta_1 \ln X_i + \varepsilon_i$$

modeli deęişen varyans sorununu

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i$$

modeline göre çoęu zaman daha düşüęe indirir. Bu sonucu doğuran neden  $\ln$  (doęal logaritma) dönüştürmesinin iki deęer arasındaki on katlık bir farkı iki kata indirmesidir.

**Örneęin;** 80 sayısı 8'in 10 katı iken  $\ln(80) = 4.328$  sayısı  $\ln(8) = 2.0794$  sayısının 2 katıdır.

$\log$  dönüştürmesinin bir başka yanı eęim katsayısı  $\beta_1$ 'in,  $Y$ 'nin  $X$ 'e göre esneklięi olmasıdır. Yani  $X$ 'deki %1'lik bir deęişime karşı  $Y$ 'de ortaya çıkan % deęişimi gösterir.

Şimdiye kadar verilen dönüştürmelerden hangisinin daha iyi olduęu deęişen varyans sorunun ciddilięine baęlıdır. Bu dönüştürmelerle ilgili bazı sorunlar:

- Çoklu modelde dönüştürme için hangi  $X$  deęişkeninin seçileceęi önceden bilinemez.
- Eęer  $Y$  ve  $X$  deęerlerinden bazıları sıfır ise  $\log$  dönüştürme uygulanamaz.
- Bazen deęişkenler ilişkisiz ya da rasgele bile olsalar bu deęişkenlerin oranları arasında korelasyon bulunduęu durumları gösterir.

$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i$  modelinde  $Y_i$  ile  $X_i$  ilişkisizken,

$$\frac{Y_i}{X_i} = \beta_0 \frac{1}{X_i} + \beta_1 + \frac{\varepsilon_i}{X_i} \text{ modelinde } \frac{Y_i}{X_i} \text{ ile } \frac{1}{X_i} \text{ çoęu zaman ilişkili bulunur.}$$

- $\sigma_i^2$  bilinmedięinde bir yolla tahmin edicileri bulunmuşsa, bütün test işlemleri büyük örneklem için geçerlidir. Küçük örneklem ya da sonlu örneklem durumlarında dönüştürme yapılmış verilere dayanan istatistiksel sonuç çıkarımların yorumlanmasında dikkat edilmelidir.

### Özet ve sonuçlar:

1. Hata terimlerinin varyansının aynı ve sabit olması yani  $\sigma^2$  olmasıdır. Bu varsayımın sağlanamaması deęişen varyans olduęunun göstergesidir.
2. Deęişen varyans EKK tahmin edicilerinin sapmasızlık (yansızlık) ve tutarlılık özelliklerini bozmaz.
3. Deęişen varyans durumunda EKK tahmin edicileri artık en küçük varyansa sahip deęiller, yani BLUE deęillerdir.
4. Hata terimlerinin deęişen varyansları  $\sigma_i^2$ 'lerin bilinmesi durumunda aęırlıklı EKK tahmin edicileri BLUE'dur.
5. Deęişen varyans varlıęında EKK tahmin edicilerin varyansları bilinen EKK formülleriyle bulunamaz. EKK formülleri ile bulunan varyanslar kullanılarak elde edilen  $t$  ve  $F$  testleri yanlış sonuçlar verir.
6. Deęişen varyansın doğurduęu sonuçları saymak, bu tanıyı koymaktan kolaydır.
7. Deęişen varyans tespit edilse bile bu durumu düzeltmek kolay deęildir. Örneklem büyükse, White standart hataları bulunup buna göre istatistiksel sonuçlar çıkarılabilir.

8. Deęişen varyansın olası örüntüsü kestirilerek buna uygun bir dönüşümle deęişen varyans sorunu çözümlenebilir.
9. EKK hata terimleri deęişen varyanslı olmakla birlikte ardışık baęımlı (otokorelasyonlu) olabilirler.