

Bölüm 4

İki Değişkenli Bağlanım Modeli - Tahmin Sorunu

4.1 Sıradan En Küçük Kareler Yöntemi

Sıradan En Küçük Kareler Yöntemi

- Bağlanım çözümlemesinde amaç, örneklem bağlanım işlevi (ÖBİ) temel alınarak anakütle bağlanım işlevinin (ABİ) olabildiğince doğru biçimde tahmin edilmesidir.
- Bunun için kullanılan en yaygın yol “*sıradan en küçük kareler*” (ordinary least squares), kısaca “*SEK*” (OLS) yöntemidir.
- SEK yönteminin 1794 yılında Alman matematikçi Carl Fredrich Gauss tarafından bulunduğu kabul edilir.
- SEK yöntemini anlamak için iki değişkenli ABİ’yi anımsayalım:

$$Y_i = \beta_1 + \beta_2 X_i + u_i$$

- ABİ gözlenemediğinden ÖBİ kullanılarak tahmin edilir:

$$\begin{aligned} Y_i &= \hat{\beta}_1 + \hat{\beta}_2 X_i + \hat{u}_i \\ &= \hat{Y}_i + \hat{u}_i \end{aligned}$$

- ÖBİ’nin kendisini bulmak için ise “*kalıntılar*” (residuals), diğer bir deyişle hata terimi kullanılır:

$$\begin{aligned}\hat{u}_i &= Y_i - \hat{Y}_i \\ &= Y_i - \hat{\beta}_1 - \hat{\beta}_2 X_i\end{aligned}$$

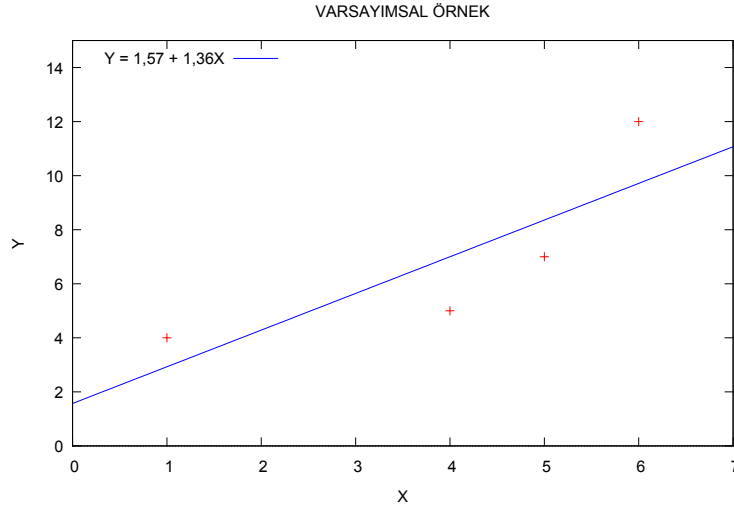
- Elimizde n tane X ve Y varken, ÖBİ'yi gözlenen Y 'lere olabildiğince yakın biçimde belirlemek istiyoruz.
- Bunun için şu ölçüt benimsenebilir:

$$\min(\sum \hat{u}_i) = \min\left(\sum(Y_i - \hat{Y}_i)\right)$$

- Ancak bu durumda artı ve eksi değerli hatalar büyük ölçüde birbirlerini etkisiz hale getirecektir.
- Ayrıca burada ÖBİ'ye ne kadar yakın ya da uzak olursa olsun tüm kalıntılar eşit önem taşımaktadır.
- Öyleyse, ÖBİ'yi kalıntılar toplamı en küçük olacak şekilde seçmek iyi bir ölçüt değildir.
- Herhangi bir veri seti için farklı $\hat{\beta}_1$ ve $\hat{\beta}_2$ değerleri farklı \hat{u}_i ve dolayısıyla da farklı $\sum \hat{u}_i^2$ toplamları verir.
- Ancak hatalar toplamı $\sum \hat{u}_i$ her zaman sıfır çıkar.
- Örnek olarak, varsayımsal bir veri seti için aşağıdaki iki ÖBİ'yi ele alalım:

$$\begin{aligned}\hat{Y}_{1i} &= 1,572 + 1,357X_i \\ \hat{Y}_{2i} &= 3,000 + 1,000X_i\end{aligned}$$

| Y_i | X_i | \hat{Y}_{1i} | \hat{u}_{1i} | \hat{u}_{1i}^2 | \hat{Y}_{2i} | \hat{u}_{2i} | \hat{u}_{2i}^2 |
|--------|-------|----------------|----------------|------------------|----------------|----------------|------------------|
| 4 | 1 | 2,929 | 1,071 | 1,147 | 4 | 0 | 0 |
| 5 | 4 | 7,000 | -2,000 | 4,000 | 7 | -2 | 4 |
| 7 | 5 | 8,357 | -1,357 | 1,841 | 8 | -1 | 1 |
| 12 | 6 | 9,714 | 2,286 | 5,226 | 9 | 3 | 9 |
| Toplam | 28 | 16 | 0 | 12,214 | | 0 | 14 |



- Artı ve eksi değerler alabilen kalıntıların toplamının küçük çıkma sorunundan kurtulmak için en küçük kareler ölçütü kullanılır:

En Küçük Kareler Ölçütü

$$\begin{aligned} \min \left(\sum \hat{u}_i^2 \right) &= \min \left(\sum (Y_i - \hat{Y}_i)^2 \right) \\ &= \min \left(\sum (Y_i - \hat{\beta}_1 - \hat{\beta}_2 X_i)^2 \right) \end{aligned}$$

- Yukarıdaki gösterimin $\hat{\beta}_1$ ve $\hat{\beta}_2$ tahmincilerine dayanan bir matematiksel işlev olduğuna dikkat ediniz.

4.1.1 SEK Tahmincilerinin Türetilmesi

Normal Denklemler

- SEK, kalıntı kareleri toplamını “enazlamak” (minimize) için, ÖBİ deęiřtir-gelerini hesaplamada basit bir “eniyleme” (optimization) yönteminden yararlanır.
- $\sum (Y_i - \hat{\beta}_1 - \hat{\beta}_2 X_i)^2$ teriminin $\hat{\beta}_1$ ve $\hat{\beta}_2$ 'ya göre kısmi türevlerini alalım:

$$\sum Y_i = n\hat{\beta}_1 + \hat{\beta}_2 \sum X_i$$

$$\sum Y_i X_i = \hat{\beta}_1 \sum X_i + \hat{\beta}_2 \sum X_i^2$$

- Burada n örneklem büyüklüğüdür.
- Yukarıdaki denklemler “*normal denklemler*” (normal equations) olarak adlandırılırlar.
- $\hat{\beta}_1$ ve $\hat{\beta}_2$ deęiřtirgeleri, normal denklemlerin eřanlı olarak çözülmesi ile bulunur:

$$\hat{\beta}_2 = \frac{n \sum X_i Y_i - \sum X_i \sum Y_i}{n \sum X_i^2 - (\sum X_i)^2}$$

$$= \frac{\sum x_i y_i}{\sum x_i^2}$$

$$\hat{\beta}_1 = \frac{\sum X_i^2 \sum Y_i - \sum X_i \sum X_i Y_i}{n \sum X_i^2 - (\sum X_i)^2}$$

$$= \bar{Y} - \hat{\beta}_2 \bar{X}$$

- \bar{X} ve \bar{Y} terimleri X ile Y 'nin örneklem ortalamalarıdır.
- Küçük harfler ise “*ortalamadan sapma*” (deviation from the mean) olarak kullanılmıřtır:

$$x_i = (X_i - \bar{X})$$

$$y_i = (Y_i - \bar{Y})$$

SEK Bağlanım Doğrusunun Özellikleri

İkili bağlanım SEK tahmincileri $\hat{\beta}_1$ ve $\hat{\beta}_2$ 'nın řu özelliklerine dikkat edelim:

- Bunlar birer nokta tahmincisidirler.
- Gözlemlenebilen örneklem deęerleri (X_i ve Y_i) cinsinden gösterilir ve dolayısıyla kolayca hesaplanabilirler.
- Örneklem verileri kullanılarak $\hat{\beta}_1$ ve $\hat{\beta}_2$ hesaplandıktan sonra, örneklem bağlanım doğrusu da kolayca çizilebilir.

SEK yöntemi ile bulunan örneklem bağlanım doğrusu ařaęıda verilen özellikleri tařır:

1. Örneklem bağlanım doğrusu, X ve Y 'nin örneklem ortalamalarından geçer. ($\bar{Y}_i = \hat{\beta}_1 + \hat{\beta}_2 \bar{X}_i$)

2. \hat{u}_i kalıntılarının ortalaması sıfırdır. ($\bar{\hat{u}}_i = 0$)
3. \hat{u}_i kalıntıları tahmin edilen Y_i 'lerle ilişkisizdir. ($\sum \hat{u}_i \hat{Y}_i = 0$)
4. \hat{u}_i kalıntıları X_i 'lerle ilişkisizdir. ($\sum \hat{u}_i X_i = 0$)
5. Tahmin edilen \hat{Y}_i 'lerin ortalaması, gözlemlenen Y_i değerlerinin ortalamasına eşittir. Bu ÖBİ'den görülebilir:

$$\begin{aligned}\hat{Y}_i &= \hat{\beta}_1 + \hat{\beta}_2 X_i \\ &= (\bar{Y} - \hat{\beta}_2 \bar{X}) + \hat{\beta}_2 X_i \\ &= \bar{Y} + \hat{\beta}_2 (X_i - \bar{X})\end{aligned}$$

Son satırın her iki yanını örneklem üzerinden toplanıp n 'ye bölünürse, $\bar{\hat{Y}} = \bar{Y}$ olarak bulunabilir.

ÖBİ'nin Sapma Biçiminde Gösterimi

- ÖBİ'nin “*sapma biçimi*” (deviation form) gösterimini bulmak için $Y_i = \hat{\beta}_1 + \hat{\beta}_2 X_i + \hat{u}_i$ işlevinin her iki yanını toplayalım:

$$\begin{aligned}\sum Y_i &= n\hat{\beta}_1 + \hat{\beta}_2 \sum X_i + \sum \hat{u}_i \\ &= n\hat{\beta}_1 + \hat{\beta}_2 \sum X_i \quad (\sum \hat{u}_i = 0 \text{ olduğu için})\end{aligned}$$

- Daha sonra bu denklemin her iki yanını n 'ye bölelim:

$$\bar{Y} = \hat{\beta}_1 + \hat{\beta}_2 \bar{X}$$

- Yukarıdaki eşitlik, örneklem bağlanımı doğrusunun X ve Y 'nin örneklem ortalamalarından geçtiğini göstermektedir.
- Son olarak yukarıdaki eşitliği ilk eşitlikten çıkaralım:

$$\begin{aligned}Y_i - \bar{Y} &= \hat{\beta}_2 (X_i - \bar{X}) + \hat{u}_i \\ y_i &= \hat{\beta}_2 x_i + \hat{u}_i\end{aligned}$$

- Sapma gösteriminde $\hat{\beta}_1$ 'nın bulunmadığına dikkat ediniz.

4.1.2 SEK Tahmincilerinin Arzulanan Özellikleri

Gauss - Markov Kanıtı

- Klasik Doğrusal Bağlanım Modeli (KDBM) varsayımları geçerli iken, en küçük kareler yöntemi ile elde edilen tahminler arzulanan bazı özellikler taşırlar.
- Gauss - Markov kanıtına göre $\hat{\beta}$ SEK tahmincilerine “*En iyi Doğrusal Yansız Tahminci*” (Best Linear Unbiased Estimator), kısaca “*EDYT*” (BLUE) adı verilir.

EDYT olan $\hat{\beta}$ şu üç arzulanan özelliği taşır:

1. Doğrusaldır. Diğer bir deyişle bağlanım modelindeki Y bağımlı değişkeninin doğrusal bir işlevidir.
2. Yansızdır. Beklenen değeri $E(\hat{\beta})$, anakütleye ait gerçek β değerine eşittir.
3. Tüm doğrusal ve yansız tahminciler içinde enaz varyanslı olandır. Kısaca en iyi ya da “*etkin*” (efficient) tahmincidir.

Gauss - Markov kanıtı hem kuramsal olarak hem de uygulamada önemlidir.

SEK Tahmincilerinin Doğrusallık Özelliği

- SEK tahmincilerinin “*doğrusallık*” (linearity) arzulanan özelliğini gösterebilmek için $\hat{\beta}_2$ formülünü şöyle yazalım:

$$\hat{\beta}_2 = \frac{\sum x_i y_i}{\sum x_i^2} = \frac{\sum x_i (Y_i - \bar{Y})}{\sum x_i^2} = \frac{\sum x_i Y_i - \bar{Y} \sum x_i}{\sum x_i^2} = \frac{\sum x_i Y_i}{\sum x_i^2}$$

- Bu basitçe şu şekilde de gösterilebilir:

$$\frac{\sum x_i Y_i}{\sum x_i^2} = \sum k_i Y_i, \quad k_i = \frac{x_i}{(\sum x_i^2)}$$

- x_i değerleri olasılıksal olmadığına göre k_i 'ler de gerçekte Y_i 'lerin önüne gelen birer “*ağırlık*” (weight) katsayısıdır.
- $\hat{\beta}_2$ bu durumda Y_i 'lerin doğrusal bir işlevidir. Basitçe $\hat{\beta}_2$ 'nın Y_i 'lerin bir ağırlıklı ortalaması olduğu da söylenebilir.
- $\hat{\beta}_1$ 'nin doğrusal olduğu da benzer biçimde kanıtlanabilir.

SEK Tahmincilerinin Yansızlık Özelliği

SEK tahmincilerinin “yansızlık” (unbiasedness) arzulanan özelliğini gösterebilmek için ağırlık terimi k 'nin şu beş özelliği önemlidir:

1. X_i 'ler olasılıksal olmadığından k_i 'ler de olasılıksal değildir.
2. $\sum k_i = 0$ 'dir. ($\sum x_i = 0$ olduğu için)
3. $\sum k_i^2 = \sum x_i^2 / \sum (x_i^2)^2 = 1 / \sum x_i^2$ olur.
4. $\sum k_i x_i = \sum x_i^2 / \sum x_i^2 = 1$ 'dir.
5. $\sum k_i x_i = \sum k_i X_i$ olur. ($\sum k_i x_i = \sum k_i (X_i - \bar{X}) = \sum k_i X_i - \bar{X} \sum k_i$ olduğu için)

Dikkat: Tüm bu özellikler k_i 'nin tanımından türetilmektedir.

- $\hat{\beta}_2$ 'nin yansız olduğunu kanıtlamak için $Y_i = \beta_1 + \beta_2 X_i + u_i$ biçimindeki ABİ'yi $\hat{\beta}_2$ formülünde yerine koyalım:

$$\begin{aligned}\hat{\beta}_2 &= \sum k_i Y_i \\ &= \sum k_i (\beta_1 + \beta_2 X_i + u_i) \\ &= \beta_1 \sum k_i + \beta_2 \sum k_i X_i + \sum k_i u_i \\ &= \beta_2 + \sum k_i u_i\end{aligned}$$

- Yukarıdaki son adımda k_i 'nin az önce sözü edilen ikinci, dördüncü ve beşinci özelliklerinden yararlanılmıştır.
- β_2 ve k_i 'nin olasılıksal olmadığını ve $E(u_i) = 0$ varsayımını anımsayalım ve her iki yanın beklenen değerini alalım:

$$\begin{aligned}E(\hat{\beta}_2) &= E(\beta_2) + \sum k_i E(u_i) \\ &= \beta_2\end{aligned}$$

- $E(\hat{\beta}_2) = \beta_2$ olduğuna göre $\hat{\beta}_2$ yansız bir tahmincidir.

SEK Tahmincilerinin Enaz Varyanslılık Özelliği

- SEK tahmincilerinin “enaz varyans” (minimum variance) arzulanan özelliğini gösterebilmek için ise β_2 'nin en küçük kareler tahmincisinden yola çıkalım:

$$\hat{\beta}_2 = \sum k_i Y_i$$

- Şimdi β_2 için başka bir doğrusal tahminci tanımlayalım:

$$\tilde{\beta}_2 = \sum w_i Y_i$$

- Buradaki ($\tilde{}$) işareti “dalga” (tilde) diye okunur.
- w_i 'ler de birer ağırlıktır ama $w_i = k_i$ olmak zorunda değildir:
- $\tilde{\beta}_2$ 'nin yansız olabilmesi için gerekli koşullara bir bakalım:

$$\begin{aligned} E(\tilde{\beta}_2) &= \sum w_i E(Y_i) \\ &= \sum w_i (\beta_1 + \beta_2 X_i) \\ &= \beta_1 \sum w_i + \beta_2 \sum w_i X_i \end{aligned}$$

- Buna göre, $\tilde{\beta}_2$ 'nin yansız olabilmesi için şunlar gereklidir:

$$\sum w_i = 0, \quad \sum w_i x_i = \sum w_i X_i = 1$$

- $\text{var}(\hat{\beta}_2) \leq \text{var}(\tilde{\beta}_2)$ savını kanıtlamak istiyoruz. Bunun için şimdi $\tilde{\beta}_2$ 'nin varyansını ele alalım:

$$\begin{aligned} \text{var}(\tilde{\beta}_2) &= \text{var}\left(\sum w_i Y_i\right) \\ &= \sum w_i^2 \text{var}(Y_i) \quad [\text{Dikkat: } \text{var}(Y_i) = \text{var}(u_i) = \sigma^2] \\ &= \sigma^2 \sum w_i^2 \quad [\text{Dikkat: } \text{cov}(Y_i, Y_j) = 0, (i \neq j)] \\ &= \sigma^2 \sum \left(w_i - \frac{x_i}{\sum x_i^2} + \frac{x_i}{\sum x_i^2} \right)^2 \\ &= \sigma^2 \sum \left(w_i - \frac{x_i}{\sum x_i^2} \right)^2 + \sigma^2 \sum \left(\frac{x_i}{\sum x_i^2} \right)^2 + 2\sigma^2 \sum \left(w_i - \frac{x_i}{\sum x_i^2} \right) \left(\frac{x_i}{\sum x_i^2} \right) \\ &= \sigma^2 \sum \left(w_i - \frac{x_i}{\sum x_i^2} \right)^2 + \sigma^2 \left(\frac{1}{\sum x_i^2} \right) \end{aligned}$$

- Son satırda bulmuş olduğumuz şey şudur:

$$\text{var}(\tilde{\beta}_2) = \sigma^2 \sum \left(w_i - \frac{x_i}{\sum x_i^2} \right)^2 + \sigma^2 \left(\frac{1}{\sum x_i^2} \right)$$

- Yukarıda en sağdaki terim w_i 'den bağımsızdır.
- Öyleyse $\text{var}(\tilde{\beta}_2)$ 'yi enazlayabilmek ilk terime bağlıdır ve ilk terimi sıfırlayan w_i değeri de şudur:

$$w_i = \frac{x_i}{\sum x_i^2} = k_i$$

- Bu durumda aşağıdaki eşitlik geçerlidir:

$$\text{var}(\tilde{\beta}_2) = \frac{\sigma^2}{\sum x_i^2} = \text{var}(\hat{\beta}_2)$$

- Demek ki w_i ağırlıkları k_i ağırlıklarına eşit olduğunda $\tilde{\beta}_2$ 'nin varyansı enazlanarak $\hat{\beta}_2$ 'nin varyansına eşitlenmektedir.
- Sonuç olarak, en küçük kareler tahmincisi $\hat{\beta}_2$ tüm yansız ve doğrusal tahmin-ciler içinde enaz varyanslı tahmincidir.

4.1.3 SEK Yönteminin Ardındaki Varsayımlar

- Ekonometrik çözümlemenin amacı yalnızca β_1 ve β_2 gibi değiştirgeleri tahmin etmek değildir. Bu değerlere ilişkin çıkarsamalar yapmak da istenir.
- Örnek olarak, \hat{Y}_i 'lerin gerçek $E(Y|X_i)$ değerlerine ne kadar yakın olduklarını bilmek önemlidir.
- Anakütle bağlanım işlevini anımsayalım:

$$Y_i = \beta_1 + \beta_2 X_i + u_i$$

- Görülüyor ki Y_i hem X_i 'ye hem de u_i 'ye bağlıdır.
- Öyleyse Y_i , β_1 ve β_2 'ye ilişkin istatistiksel çıkarım yapmak için X_i ve u_i 'nin nasıl oluşturulduğunu bilmek gereklidir.
- Bu noktada Gaussçu “*Klasik Doğrusal Bağlanım Modeli*” (Gaussian Classical Linear Regression Model), kısaca “*KDBM*” (CLRM) 10 temel varsayım yapar.

Varsayım 1

Bağlanım modeli değiştirgelerde doğrusaldır:

$$Y_i = \beta_1 + \beta_2 X_i + u_i$$

- Ancak değişkenlerde doğrusallık zorunlu değildir.
- Değiştirgelerde doğrusallık varsayımı KDBM'nin başlangıç noktasıdır.

Varsayım 2

X değerleri tekrarlı örneklemlerde değişmez.

- Bu varsayım X 'in olasılıksal olmadığını söyler.
- Buna göre X ve Y değerlerinin rastsal $\{X, Y\}$ çiftleri şeklinde elde edilmemiş olduğu kabul edilir.
- Diğer bir deyişle, gelir düzeyi başta örneğin 80 olarak belirlendikten sonra rastsal bir aile seçildiğini varsayıyoruz.
- Buna göre elimizdeki çözümleme açıklayıcı X değişkenine göre bir koşullu bağlanım çözümlemesidir.
- X ve Y değerlerinin birlikte örneklenebilmesi, bazı ek koşulların sağlanması ile geçerli olur. Bu duruma ise “*Neo-Klasik Doğrusal Bağlanım Modeli*” (NKDBM) denir.

Varsayım 3

u_i hata teriminin ortalaması sıfırdır:

$$E(u_i|X_i) = 0$$

- Buna göre, modelde açıkça yer almayan ve dolayısıyla u_i içine katılmış olan etmenlerin Y 'yi kurallı bir şekilde etkilemediği varsayılmaktadır.
- Artı değerli u_i 'ler eksi değerli u_i 'leri götürmeli ve böylece bunların Y üzerindeki ortalama etkileri sıfır olmalıdır.

Varsayım 4

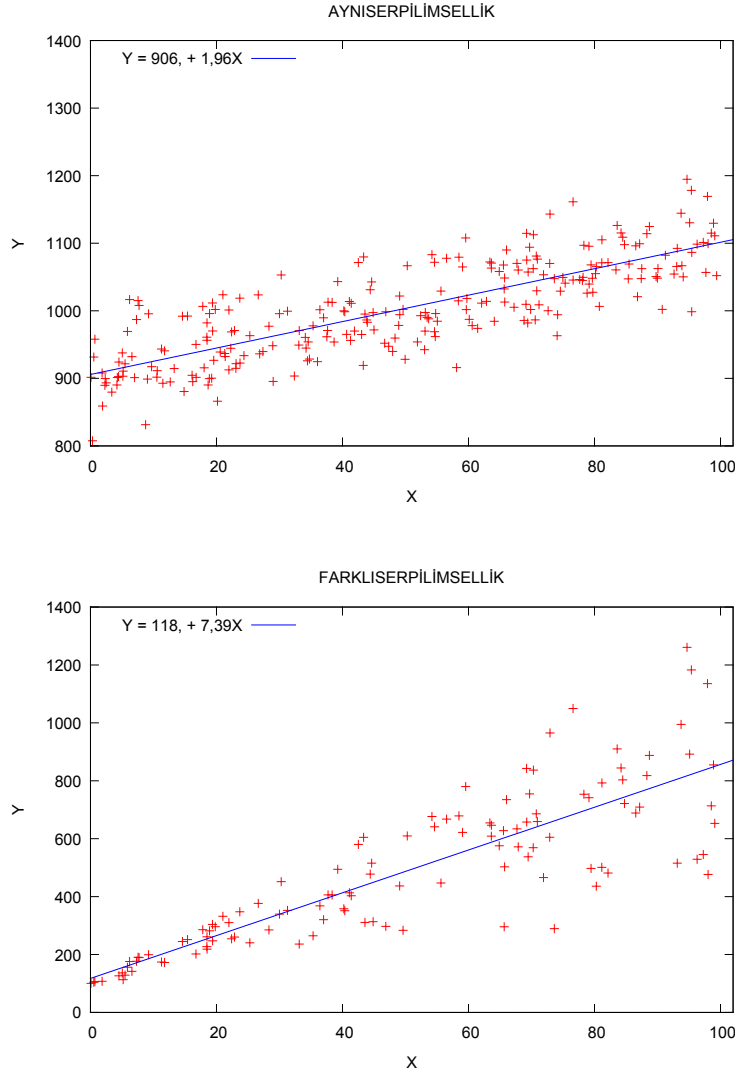
u_i hata teriminin varyansı tüm gözlemler için sabittir:

$$\text{var}(u_i|X_i) = \sigma^2$$

- “*Aynıserpilimsellik*” (homoscedasticity) varsayımına göre farklı X değerlerine karşılık gelen tüm Y 'ler eşit önemdedir.
- Tersi durum ise “*farklıserpilimsellik*” (heteroscedasticity) durumudur:

$$\text{var}(u_i|X_1) \neq \text{var}(u_2|X_2) \neq \dots \neq \text{var}(u_n|X_n).$$

- Farklıserpilimsellik durumunda çeşitli X değerlerine karşılık gelen Y değerlerinin güvenilirlikleri aynı olmaz.
- Bu yüzden kendi ortalaması etrafında farklı sıklıkta yayılan Y 'leri farklı ağırlıklar vererek değerlendirmek gereklidir.


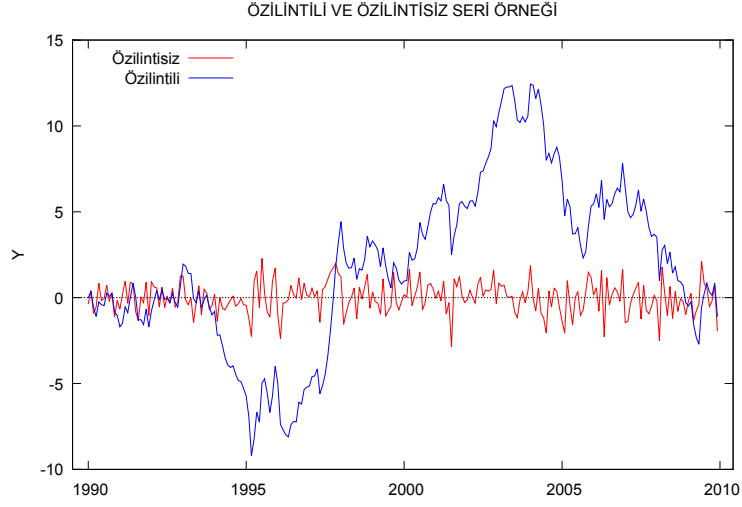



Varsayım 5

Hatalar arasında “özilinti” (autocorrelation) yoktur.

- Eğer “bozukluklar” (disturbances) birbirlerini kurallı biçimde izlerlerse özilinti ortaya çıkar.
- ABİ’yi $Y_t = \beta_1 + \beta_2 X_t + u_t$ olarak kabul edelim ve u_t ile u_{t-1} de aynı yönde ilişkili olsun.
- Bu durumda, Y_t yalnızca X_t ’ye değil u_t ’ye de bağlı olur ve bu nedenle u_t ’yi bir ölçüde u_{t-1} belirler.

- Bu sorunla karşılaşmamak için hatalar arasında “*serisel ilinti*” (serial correlation) olmadığı varsayılır.



**Varsayım 6**

Hata terimi u_i ile X_i 'nin kovaryansı sıfırdır:

$$\text{cov}(u_i, X_i) = 0$$

- Eğer X ve u ilişkiliyse, ikisinin de Y üzerindeki tekil etkilerini bulmak olanaksızlaşır.
- Ayrıca, eğer X ile u aynı yönde ilişkiliyse, X arttıkça u da artarak farklıserpilimsellik sorununa yol açar.

- Eğer 2. varsayım (X 'in rastsal olmaması) ve 3. varsayım ($E(u_i|X_i) = 0$) geçerliyse, 6. varsayım da kendiliğinden gerçekleşmiş olur.

Varsayım 7

Gözlem sayısı n , tahmin edilecek anakütle katsayısından fazla olmalıdır.

- İki bilinmeyeni (β_1 ve β_2) bulmak için en az iki noktaya gereksinim vardır.
- Bu koşul çözümlenmenin matematiksel olarak yapılabilmesi için gereklidir.
- Diğer yandan n serbestlik derecesi açısından önemlidir. Bu nedenle sağlıklı sonuçlar için örneklemin yeterince büyük olmasının ayrıca gerekli olduğu unutulmamalıdır.

Varsayım 8

Belli bir örneklemden X değerlerinin hepsi aynı olamaz:

$$\text{var}(X) \neq 0$$

- Eğer bütün X değerleri aynı olursa:

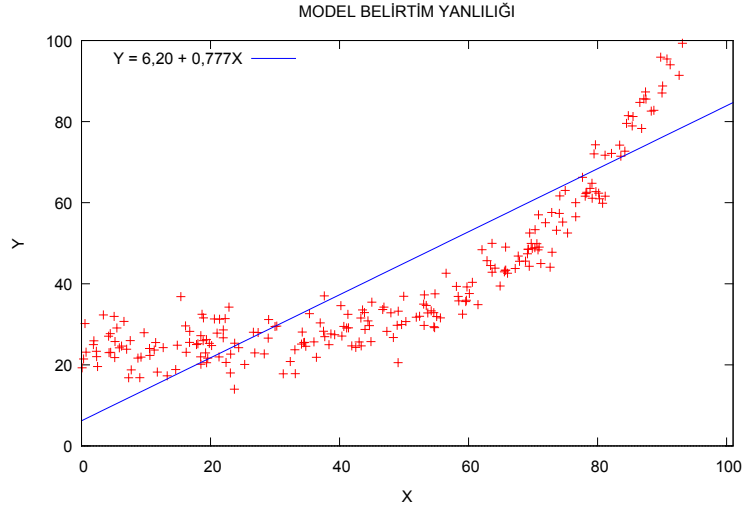
$$\begin{aligned} X_i &= \bar{X}, \\ x_i &= X_i - \bar{X} \quad \text{olduğundan} \\ \hat{\beta}_2 &= \frac{\sum x_i y_i}{\sum x_i^2} \quad \text{formülünün paydası sıfır çıkar.} \end{aligned}$$

- Kısaca değişkenler değişmelidir.

Varsayım 9

Bağlanım modeli doğru biçimde belirtilmiş olmalıdır.

- Bağlanım çözümü sonuçlarının güvenilirliği, seçilen modele bağlıdır.
- Özellikle de bir iktisadi olguyu açıklayan birden fazla kuram bulunuyor ise ekonometrici çok dikkatli olmalıdır.
- Her durumda modelin işlev biçiminin ne olduğu, değişken ve değiştirgelerde doğrusal olup olmadığı konuları iyice sorgulanmalıdır.
- Bağlanım modeli yanlış olduğu zaman “*model belirtim hatası*” (model specification error) ortaya çıkar.



Varsayım 10

“Tam çoklueşdoğrusallık” (exact multicollinearity) yoktur.

- Tam çoklueşdoğrusallık durumunda bağlanım katsayıları belirsiz ve bu katsayıların ölçünlü hataları da sonsuz olur.

KDBM Varsayımlarının Gerçekçiliği

Ünlü ekonomist Milton Friedman’ın “varsayımların yersizliği” tezine göre gerçek dışılık bir üstünlüktür:

“Önemli olabilmek için . . . bir önsav, varsayımlarında betimsel olarak gerçek dışı olmalıdır.”

- Ekonometrideki KDBM’nin, fiyat kuramındaki tam rekabet modelinin karşılığı olduğu söylenebilir.
- Diğer bir deyişle öne sürmüş olduğumuz bu 10 varsayım gerçekleri tümüyle yansıtmak için değil, konuyu yavaş yavaş geliştirebilmeyi kolaylaştırmak amacıyla önemlidir.
- Bu varsayımların gerçekleşmemesi durumunda doğacak sonuçları ise ilerideki bölümlerde inceleyeceğiz.

4.2 SEK Yönteminin Güvenilirliği

4.2.1 SEK Tahmincilerinin Ölçünlü Hataları

- Sıradan en küçük kareler tahmincilerinin örneklem verilerinin birer işlevi olduğunu anımsayalım:

$$\begin{aligned}\hat{\beta}_2 &= \frac{n \sum X_i Y_i - \sum X_i \sum Y_i}{n \sum X_i^2 - (\sum X_i)^2} \\ &= \frac{\sum x_i y_i}{\sum x_i^2}\end{aligned}$$

$$\begin{aligned}\hat{\beta}_1 &= \frac{\sum X_i^2 \sum Y_i - \sum X_i \sum X_i Y_i}{n \sum X_i^2 - (\sum X_i)^2} \\ &= \bar{Y} - \hat{\beta}_2 \bar{X}\end{aligned}$$

- Veriler örneklemden örnekleme değişeceği için tahminler de buna bağlı olarak değişecektir.
- Öyleyse $\hat{\beta}_1$ ve $\hat{\beta}_2$ tahmincilerinin güvenilirliği için bir ölçüte gereksinim vardır.
- İstatistikte rastsal bir değişkenin doğruluk derecesi “ölçünlü hata” (standard error), kısaca “öh” (se) ile ölçülür:

Ölçünlü Hata

Ölçünlü hata, bir tahminciye ait örneklem dağılımının kendi ortalamasından ortalama olarak ne kadar saptığını gösterir. Örneklem dağılımı varyansının artı değerli kare köküdür.

- Başta sözü edilmiş olan Gaussçu varsayımlar geçerli iken SEK tahmincilerinin ölçünlü hataları aşağıdaki gibidir:

$$\text{var}(\hat{\beta}_2) = \frac{\sigma^2}{\sum x_i^2}$$

$$\text{öh}(\hat{\beta}_2) = \frac{\sigma}{\sqrt{\sum x_i^2}}$$

$$\text{var}(\hat{\beta}_1) = \frac{\sum X_i^2}{n \sum x_i^2} \sigma^2$$

$$\text{öh}(\hat{\beta}_1) = \sqrt{\frac{\sum X_i^2}{n \sum x_i^2}} \sigma$$

- Burada
var değişirlik ya da varyansı,
öh ölçünlü hatayı,
 σ^2 ise bağlanımın sabit varyansını
göstermektedir.

- u_i 'nin sabit varyansını veren σ^2 şöyle tahmin edilir:

$$\hat{\sigma}^2 = \frac{\sum \hat{u}_i^2}{n - 2}$$

- Buradaki $\hat{\sigma}^2$, bilinmeyen σ^2 'nin SEK tahmincisidir.
- $\sum \hat{u}_i^2$ terimine “*kalıntı kareleri toplamı*” (residual sum of squares), kısaca “*KKT*” (RSS) denir ve şöyle bulunur:

$$\sum \hat{u}_i^2 = \sum y_i^2 - \hat{\beta}_2^2 \sum x_i^2$$

- $n - 2$ değeri ise iki değişkenli çözümleme için geçerli serbestlik derecesidir.

Serbestlik Derecesi

“*Serbestlik derecesi*” (degree of freedom), örneklemdaki toplam gözlem sayısı (n) eksi bunlar üzerine konulmuş olan bağımsız ve doğrusal sınırlama sayısıdır.

- Örnek olarak, KKT'nin hesaplanabilmesi için önce $\hat{\beta}_1$ ve $\hat{\beta}_2$ değerlerinin bulunmuş olması gereklidir:

$$\sum \hat{u}_i^2 = \sum (Y_i - \hat{\beta}_1 - \hat{\beta}_2 X_i)^2$$

- Dolayısıyla bu iki tahminci KKT üzerine iki sınırlama getirir.
- Bu durumda, KKT'yi ve dolayısıyla da ölçünlü hatayı doğru hesaplayabilmek için aslında elde n değil $n - 2$ sayıda bağımsız gözlem vardır.

SEK tahmincileri $\hat{\beta}_1$ ve $\hat{\beta}_2$ 'nin varyans formüllerini anımsayalım:

$$\text{var}(\hat{\beta}_2) = \frac{\sigma^2}{\sum x_i^2} \quad \text{var}(\hat{\beta}_1) = \frac{\sum X_i^2}{n \sum x_i^2} \sigma^2$$

$\hat{\beta}_1$ ile $\hat{\beta}_2$ tahmincilerinin varyanslarının ve dolayısıyla bunların ölçünlü hatalarının şu özellikleri önemlidir:

1. Örneklem büyüklüğü n arttıkça $\sum x_i^2$ toplamındaki terim sayısı da artar. Böylece n büyüdükçe $\hat{\beta}_1$ ve $\hat{\beta}_2$ 'nin doğruluk dereceleri de artar.
2. $\hat{\beta}_1$ ve $\hat{\beta}_2$, verili bir örnekleme birbirleri ile ilişkili olabilirler. Bu bağımlılık aralarındaki kovaryans ile ölçülür:

$$\text{cov}(\hat{\beta}_1, \hat{\beta}_2) = -\bar{X} \text{var}(\hat{\beta}_2)$$

3. Eğer \bar{X} artı değerli ise kovaryans da eksi değerli olur. Bu durumda eğer β_2 katsayısı olduğundan büyük tahmin edilir ise β_1 de olduğundan küçük tahmin edilmiş olur.

4.2.2 Belirleme Katsayısı r^2

- Eldeki gözlemler çoğunlukla bağlanım doğrusu üzerinde yer almazlar.
- Artı ya da eksi işaretli \hat{u}_i hataları ile karşılaşıldığına göre örneklem bağlanım doğrusunun eldeki verilerle ne ölçüde örtüştüğünü gösteren bir ölçüte gereksinim vardır:

Belirleme Katsayısı

“Belirleme katsayısı” (coefficient of determination) ya da r^2 (çoklu bağlanımda R^2), örneklem bağlanım işlevinin verilere ne kadar iyi yakıştığını gösteren özet bir ölçüttür.

Belirleme katsayısını hesaplamak için, $y_i = \hat{y}_i + \hat{u}_i$ eşitliğinin iki yanının karesi alınır ve örneklem boyunca toplanır:

$$\begin{aligned} \sum y_i^2 &= \sum \hat{y}_i^2 + \sum \hat{u}_i^2 + 2 \sum \hat{y}_i \hat{u}_i \\ &= \sum \hat{y}_i^2 + \sum \hat{u}_i^2 \\ &= \hat{\beta}_2^2 \sum x_i^2 + \sum \hat{u}_i^2 \\ \text{TKT} &= \text{BKT} + \text{KKT} \end{aligned}$$

Burada

TKT “Toplam Kareleri Toplamı” (Total Sum of Squares),

BKT “Bağlanım Kareleri Toplamı” (Regression Sum of Squares),

KKT “Kalıntı Kareleri Toplamı” (Residual Sum of Squares)

anlamına gelmektedir.

- Yukarıdaki $\sum \hat{y}_i \hat{u}_i$ teriminin SEK bağlanım doğrusunun 3. özelliğinden dolayı sifira eşit olduğuna dikkat ediniz.

$$\begin{aligned} \sum y_i^2 &= \hat{\beta}_2^2 \sum x_i^2 + \sum \hat{u}_i^2 \\ \text{TKT} &= \text{BKT} + \text{KKT} \end{aligned}$$

Yukarıdaki eşitliğin her iki yanını TKT'ye bölelim:

$$1 = \frac{\text{BKT}}{\text{TKT}} + \frac{\text{KKT}}{\text{TKT}}$$

Buna göre r^2 aşağıdaki gibi tanımlanır:

Belirleme Katsayısı

$$r^2 = \frac{\sum \hat{y}_i^2}{\sum y_i^2} = \frac{\sum (\hat{Y}_i - \bar{Y})^2}{\sum (Y_i - \bar{Y})^2} = \frac{\text{BKT}}{\text{TKT}} = 1 - \frac{\text{KKT}}{\text{TKT}}$$

r^2 'nin iki temel özelliğinden söz edilebilir:

1. r^2 eksi değer almayan bir büyüklüktür.
2. Sınırları $0 \leq r^2 \leq 1$ 'dir.

Buna göre:

- Eğer $r^2 = 1$ olursa bu kusursuz bir yakışma demektir. Bu durumda rastsal hata yoktur ve tüm gözlemler bire bir bağlanım doğrusu üzerinde yer almaktadır.
- Sifira eşit bir r^2 ise bağımlı değişkenle açıklayıcı değişken arasında hiçbir ilişkinin olmadığı ($\hat{\beta}_2 = 0$) anlamına gelir.

r^2 ile yakın ilişkili ama kavramsal olarak çok uzak bir büyüklük “ilinti katsayısı” (coefficient of correlation), kısaca r 'dir:

İlinti Katsayısı

$$r = \pm \sqrt{r^2}$$

- r değeri, bağımlı ve açıklayıcı değişkenler arasındaki doğrusal bağımlılığın bir ölçüsüdür.
- -1 ve $+1$ arasında yer alır: $-1 \leq r \leq 1$.
- Bakışımıdır: $r_{XY} = r_{YX}$.
- Sıfır noktasından ve ölçekten bağımsızdır.
- Herhangi bir neden-sonuç ilişkisi içermez.
- İki değişken arasında sıfır ilinti ($r = 0$) mutlaka bağımsızlık göstermez çünkü r yalnızca doğrusal ilişkiyi ölçer.

4.2.3 Monte Carlo Yöntemi

- KDBM varsayımları altında SEK tahmincilerinin EDYT (En iyi Doğrusal Yansız Tahminci) olmalarını sağlayan bazı arzulan özellikler taşıdıklarını anımsayalım.
- EDYT özelliklerinin geçerliliği, bir “benzetim” (simulation) yöntemi olan Monte Carlo deneyleri ile doğrulanabilir.
- Bu yöntem, anakütle katsayılarını tahmin eden süreçlerin istatistiksel özelliklerini incelemede sıkça kullanılmaktadır.
- Monte Carlo aynı zamanda istatistiksel çıkarsamanın temeli sayılan “tekrarlı örnekleme” (repeated sampling) kavramının anlaşılması için de yararlı bir araçtır.

Bir Monte Carlo deneyi aşağıdaki gibi yapılır:

1. Anakütle katsayıları seçilir. Örnek: $\beta_1 = 20$ ve $\beta_2 = 0,6$.
2. Bir örneklem büyüklüğü seçilir. Örnek: $n = 25$.
3. Her gözlem için bir X değeri belirlenir.
4. Bir rastsal sayı oluşturucu kullanılarak u_i kalıntıları üretilir.
5. β_1, β_2, X_i 'ler ve u_i 'ler kullanılarak Y_i değerleri bulunur.
6. Bu şekilde üretilen Y_i değerleri X_i 'ler ile bağlanıma sokulur ve $\hat{\beta}_1$ ve $\hat{\beta}_2$ SEK tahmincileri hesaplanır.
7. İşlem tekrarlanır (örneğin 1000 kez) ve rastsallıktan dolayı her seferde değişen tahminlerin ortalamaları $(\bar{\hat{\beta}}_1, \bar{\hat{\beta}}_2)$ alınır.
8. Eğer $\bar{\hat{\beta}}_1$ ve $\bar{\hat{\beta}}_2$ değerleri β_1 ve β_2 'ye aşağı yukarı eşit ise, deney SEK tahmincilerinin yansızlığını, diğer bir deyişle $E(\hat{\beta}_1) = \beta_1$ ve $E(\hat{\beta}_2) = \beta_2$ olduğunu saptamış sayılır.

4.3 Sayısal Bir Örnek

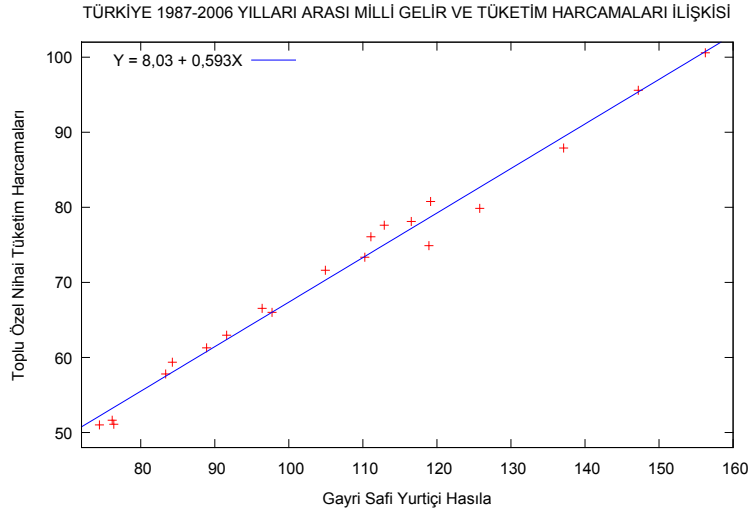
Sayısal Bir Örnek

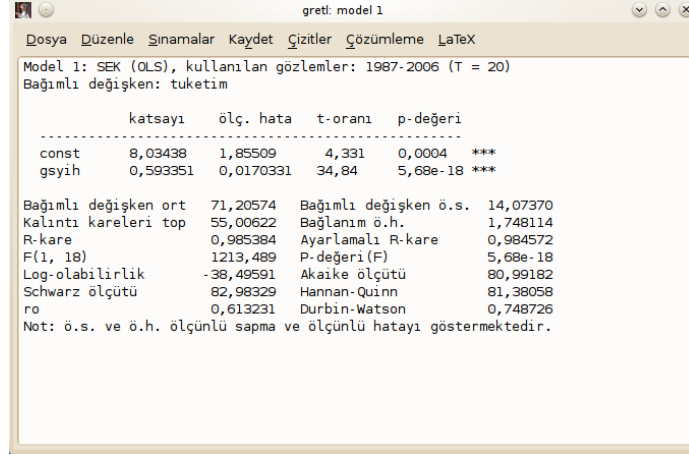
- Ele almış olduğumuz bazı kavramları sayısal bir örnek yardımı ile gözden geçirelim. Türkiye’de 1987–2006 arası toplam tüketim harcamaları ve GSYH verileri şöyledir:

Çizelge: Türkiye’de Tüketim ve GSYH (1987–2006)

| Yıl | C | Y | Yıl | C | Y |
|------|--------|---------|------|---------|---------|
| 1987 | 51.019 | 74.416 | 1997 | 77.620 | 112.892 |
| 1988 | 51.638 | 76.143 | 1998 | 78.113 | 116.541 |
| 1989 | 51.105 | 76.364 | 1999 | 76.077 | 111.083 |
| 1990 | 57.803 | 83.371 | 2000 | 80.774 | 119.147 |
| 1991 | 59.366 | 84.271 | 2001 | 73.356 | 110.267 |
| 1992 | 61.282 | 88.893 | 2002 | 74.894 | 118.923 |
| 1993 | 66.545 | 96.391 | 2003 | 79.862 | 125.778 |
| 1994 | 62.962 | 91.600 | 2004 | 87.897 | 137.110 |
| 1995 | 66.011 | 97.729 | 2005 | 95.594 | 147.200 |
| 1996 | 71.614 | 104.940 | 2006 | 100.584 | 156.249 |

- Toplu özel nihai tüketim harcamalarını (Y), gayri safi yurtiçi hasıla (X) ile ilişkilendirmek istiyor olalım.





| | katsayı | ölç. hata | t-oranı | p-değeri |
|-------|----------|-----------|---------|--------------|
| const | 8,03438 | 1,85509 | 4,331 | 0,0004 *** |
| gsyih | 0,593351 | 0,0170331 | 34,84 | 5,68e-18 *** |

Bağımlı değişken ort 71,20574 Bağımlı değişken ö.s. 14,07370
Kalıntı kareleri top 55,00622 Bağlanım ö.h. 1,748114
R-kare 0,985384 Ayarlamalı R-kare 0,984572
F(1, 18) 1213,489 P-değeri (F) 5,68e-18
Log-olabilirlik -38,49591 Akaike ölçütü 80,99182
Schwarz ölçütü 82,98329 Hannan-Quinn 81,38058
ro 0,613231 Durbin-Watson 0,748726
Not: ö.s. ve ö.h. ölçünlü sapma ve ölçünlü hatayı göstermektedir.

- Gretl çıktısına göre marjinal tüketim eğilimi (MTE) 0,59'dur.
- Buna göre gelir 1 lira arttığında tüketimin de 59 kuruş artması beklenmektedir.
- Sabit terim, toplam gelir sıfır olduğunda toplam tüketimin yaklaşık 8 milyon lira olacağını göstermektedir.
- Sıfır gelirin gözlem aralığı dışında kalan ve gerçek hayatta olanaksız bir değer olmasından dolayı, sabit terimin böylesi bir mekanik yorumu iktisadi anlam içermemektedir.
- Gretl $\hat{\beta}_1$, $\hat{\beta}_2$ ve \hat{u}_i için ölçünlü hataları sırasıyla 1,85509 ve 0,0170331 ve 1,748114 olarak hesaplamıştır.
- Yukarıdaki değerlerin karesi alınarak $\text{var}(\hat{\beta}_1) = 3,44136$ ve $\text{var}(\hat{\beta}_2) = 0,000290126$ ve $\hat{\sigma}^2 = 3,05590$ varyansları da kolayca bulunabilir.
- $r^2 = 0,985$ değeri ise bağlanım modelinin verilere gerçekçi kabul edilemeyecek kadar iyi yakıştığını göstermektedir.

Önümüzdeki Dersin Konusu ve Ödev

Ödev

Kitaptan *Bölüm 3* “Two-Variable Regression Model: The Problem of Estimation” okunacak.

Önümüzdeki Ders

Normallik Varsayımı ve Ençok Olabilirlik Yöntemi

UADMK Açık Lisans Bilgisi

İşbu belge, “Creative Commons Attribution-Non-Commercial ShareAlike 3.0 Unported” (CC BY-NC-SA 3.0) lisansı altında bir açık ders malzemesi olarak genel kullanıma sunulmuştur. Eserin ilk sahibinin belirtilmesi ve geçerli lisansın korunması koşuluyla özgürce kullanılabilir, çoğaltılabilir ve değiştirilebilir. Creative Commons örgütü ve “CC-BY-NC-SA” lisansı ile ilgili ayrıntılı bilgi “<http://creativecommons.org>” adresinde bulunmaktadır. Bu ekonometri ders notları setinin tamamına “<http://www.acikders.org.tr>” adresinden ulaşılabilir.

A. Talha Yalta
TOBB Ekonomi ve Teknoloji Üniversitesi
Ekim 2011 