

## Çoklu Doğrusal Bağntı (CDB)

\* CDB, genel olarak açıklayıcı (bağımsız) değişkenler arasındaki lineer ilişkiyi ifade eder. Buradaki 'lineer' (doğrusal) kelimesi önemlidir.

\* CDB bu ilişkinin lineer olmasıyla ilgilidir. Eğer bağımsız değişkenler arasındaki ilişki non-linear bir form alıyorsa CDB'ye sebep olmaz.

\* CDB sadece çoklu regresyonda ortaya çıkan bir problemdir. Bu nedenle verilen örnekler sadece çoklu doğrusal regresyon üzerinden verilecektir. CDB neden basit regresyonda gözlenmez?

### Çoklu Doğrusal Regresyon

Hatırlatma

$$\text{Model} \rightarrow y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + u \quad (1)$$

$$\text{Model indeksle yazıldı} \rightarrow y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_k X_{ik} + u_i \quad (2)$$

$y \Rightarrow$  bağımlı değişken

$X = \{X_1, X_2, \dots, X_k\} \Rightarrow$  bağımsız değişkenler

$u \Rightarrow$  stokastik hata terimi

$n =$  gözlem sayısı

$i \Rightarrow i.$  gözlem (indeks)

$\beta_0 \Rightarrow$  sabit terim

$\beta_j = \{\beta_1, \beta_2, \dots, \beta_k\} \Rightarrow$  kısmi eğim parametreleri

$j =$  kısmi eğim parametreleri için indeks

CDB4: Örnekte (ve bu nedenle anaküttele) bağımsız değişkenlerin hiçbirini sabit değildir ve bağımsız değişkenler arasında tam doğrusal bağıntı yoktur.

$\downarrow$   
= Tam Çoklu Doğrusal bağıntı

$\rightarrow$  Herhangi bir  $X$  diğer  $X$ 'lerin lineer bir kombinasyonu olarak yazılmaz.

\* Bu varsayım  $X$ 'lerin birbirleriyle ilişkili olmasına izin verir. İzin verilmeyen tam lineer bir ilişkinin olmasıdır.

$\rightarrow$  Ne demek?

\* X'ler tam lineer ilişkili olursa SEKK parametre tahmincilerinin tahmini matematiksel olarak mümkün olmaz. (Daha sonra gösterilecek).

\* Bu varsayımına göre bağımsız değişkenler ilişkili olabilir (non-linear ve lineer olarak). X'ler arasında ilişkiye izin vermezsek çoklu regresyondan istediğimiz faydayı alamayız. Bu noktaya da daha sonra bir örnek ile değineceğiz.

\* Daha önce 1 numaralı denklemlerle verilen modeli SEKK yöntemi ile tahmin ettiğimizi düşünelim

$$\text{ÖRF} \quad \hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_{i1} + \hat{\beta}_2 X_{i2} + \dots + \hat{\beta}_k X_{ik} \quad (3)$$

\* 3 numaralı denklemlerdeki parametre tahmincileri ve varyansları her hangi bir kısmi eğim parametresi  $\hat{\beta}_J$  için şu şekilde yazılabilir.

$$\hat{\beta}_J = \frac{\sum_{i=1}^n \hat{r}_{iJ} y_i}{\sum_{i=1}^n \hat{r}_{iJ}^2} \quad (4)$$

$$\text{Var}(\hat{\beta}_J) = \frac{\sigma^2}{SST_J (1 - R_J^2)} \quad (5)$$

\* Bu noktada anlamlılığını arttırmak için 1 numaralı denklemlerle verilen modeldeki bağımsız değişken sayısını 2'ye düşürelim ve ÖRF-yi (3. numaralı denklem ile verildi) yeniden yazalım. Ayrıca  $\hat{\beta}_J$  yerine  $\hat{\beta}_1$ , 4. ve 5. denklemler yerine de 8. ve 9. denklemleri yazalım.

$$\text{model} \Rightarrow y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + u_i \quad (6)$$

$$\text{ÖRF} \Rightarrow \hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_{i1} + \hat{\beta}_2 X_{i2} \quad (7)$$

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n \hat{r}_{i1} y_i}{\sum_{i=1}^n \hat{r}_{i1}^2} \quad (8)$$

$$\text{Var}(\hat{\beta}_1) = \frac{\sigma^2}{SST_1 (1 - R_1^2)} \quad (9)$$

\* Burada  $\hat{r}_{i1}$ ,  $X_{i1}$ 'in  $X_{i2}$  üzerine regresyonunda elde edilen artıklar.

$$X_{i1} = \hat{\delta}_0 + \hat{\delta}_1 X_{i2} + \hat{r}_{i1} \quad (10)$$

$$y_i = \hat{\beta}_0 + \hat{\beta}_1 \hat{r}_{i1} + \text{kalıntı}$$

$R_1^2 \Rightarrow$  bu modelin belirlilik katsayısı

$SST_1 \Rightarrow$  toplam kareler toplamı

$$SST_1 = \sum_{i=1}^n (X_{i1} - \bar{X}_1)^2$$

\* 6. numaralı denklem ile verilen modelde GDR4 varsayımı (3)

• Basitçe bağımsız değişkenlerden hiçbirini kalan bağımsız değişkenlerin kombinasyonu olarak yazılamazlar.

• Resmi olarak ise aşağıdaki denklemi sağlayan, (0,0) haricinde hiçbir  $(\lambda_1, \lambda_2)$  ikilisi yazılamazlar.

$$\lambda_1 X_1 + \lambda_2 X_2 = 0$$

• Eğer  $(\lambda_1, \lambda_2)$  ikilisi (0,0) haricinde değerler alabilirse yani  $X_1$  ve  $X_2$  arasında lineer bağıntı varsa tam oklu doğrusal bağıntı (ADB) problemi vardır ve 7. denklem tahmin edilemez (parametre tahmincileri ve varyansları hesaplanamaz). Aksi durumda  $X_1$  ve  $X_2$  bağımsızdır ve 7. denklem hesaplanabilir.

ÖR 1:  $X_1 - 2X_2 = 0 \Rightarrow X_1 = 2X_2 \Rightarrow \begin{matrix} \lambda_1 = 1 \\ \lambda_2 = 2 \end{matrix}$  ise

• Bu durumda tam ADB problemi var. Bağımsız değişkenler lineer olarak birbirine bağımlı. Hesap yapılamaz.

• Bu durumu önce mantık ve modelin kendisini kullanarak anlamaya çalışalım.

\*  $y_i = B_0 + B_1 X_{i1} + B_2 X_{i2} + u_i$   
 $y_i = B_0 + B_1 2X_{i2} + B_2 X_{i2} + u_i$   $\left. \begin{matrix} X_1 = 2X_2 \\ \text{yerine koy} \end{matrix} \right\}$   
 $y_i = B_0 + (2B_1 + B_2) X_{i2} + u_i$

$$y_i = B_0 + \alpha X_{i2} + u_i$$

$$\boxed{\alpha = 2B_1 + B_2} \Rightarrow$$

SEKK yöntemi ile  $\alpha$  bulunabilir fakat  $B_1$  ve  $B_2$  değerleri tekil olarak bulunamazlar.

\*  $y = \text{maaş}$ ,  $X_1 = \text{eğitim süresi}$ ,  $X_2 = \text{Eğitim süresinin 2 katını gösterebilir}$ .

↳ Eğitim süresi  $\Rightarrow$  maaşı ne kadar etkiler?

$$y = B_0 + B_1 X_1 + B_2 X_2 + u$$

Diger hersey sabit iken

↓ Aynı bilgi

Biri yorumlamasını hatırlayın

"Ceteris paribus  $X_1$  1 birim artınca  $y$ 'nin ne kadar arttığını gösterin"  $\Rightarrow$   $X_1$  1 birim artınca  $X_2$  nasıl sabit kalabilir?

\* Hesaplamanın yapılmadığını göstermenin bir diğer yolu ise  $\hat{\beta}_1$  ve  $\text{Var}(\hat{\beta}_1)$ 'in formüllerini kullanmaktır.

$$\hat{\beta}_1 = \frac{\sum \hat{r}_{i1} y_i}{\sum \hat{r}_{i1}^2} \quad (8) \quad \text{Var}(\hat{\beta}_1) = \frac{\sigma^2}{\text{SST}_1 (1 - R_1^2)} \quad (9)$$

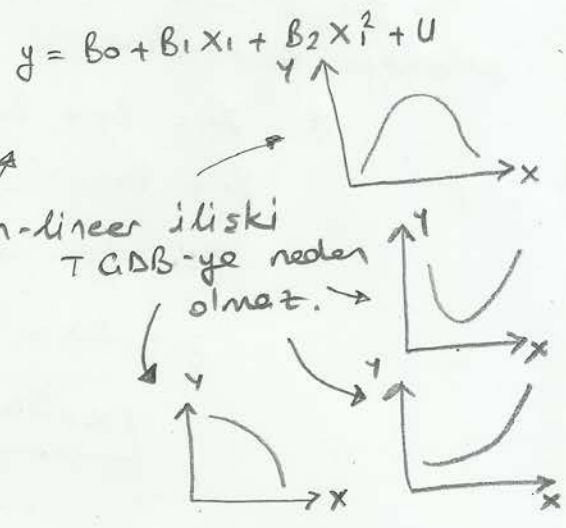
$$X_{i2} = \hat{\delta}_0 + \hat{\delta}_1 X_{i1} + \hat{r}_{i2} \quad (10)$$

- Eğer  $X_1$  ve  $X_2$  arasında tam bir bağıntı varsa  $\hat{\delta}_1 = 2$  bulunacak ve  $\hat{r}_{i2}$ 'nin tüm değerleri sıfır çıkacaktır (10. denklem). Bu durumda da  $R_1^2 = 1$  olacaktır.
- $\sum \hat{r}_{i1}^2 = 0$  olacak ve  $\hat{\beta}_1$  tanımsız olacaktır.
- $R_1^2 = 1$  olduğundan  $\text{Var}(\hat{\beta}_1)$  da tanımsız olacaktır.

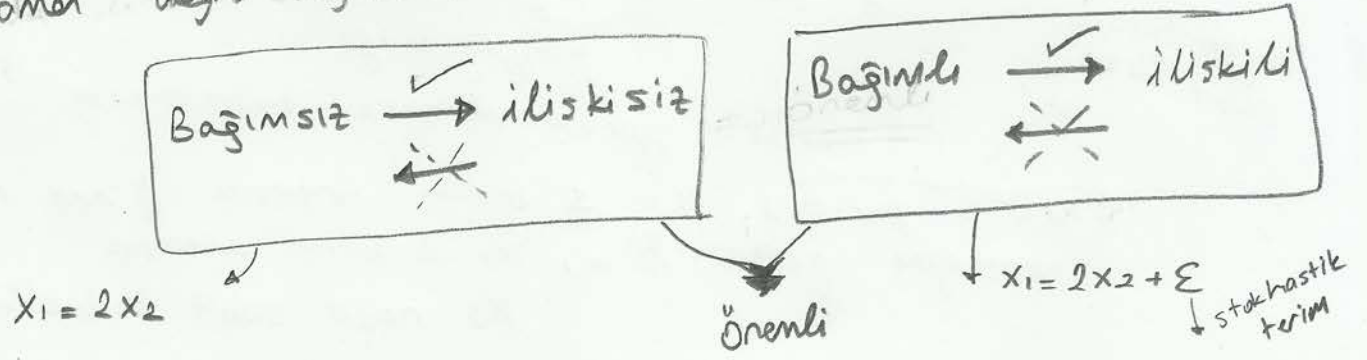
\* Tam okulu bağıntının ortaya çıktığı bazı örnekler bakalım. Ama bunun için 6. denklemi biraz değiştirelim

$$y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \beta_3 X_{i3} + u_i$$

- $X_1 = 3X_2 \Rightarrow$  TCDB var
- $X_1 = X_2 + X_3 \Rightarrow$  " "
- $X_3 = 2X_2 + 4 + 3X_1 \Rightarrow$  " "
- $X_1 = X_2^2 \Rightarrow$  TCDB YOK  $\rightarrow$  Non-linear ilişki
- $\log(X_1) = \log(X_2^2) \Rightarrow$  TCDB VAR  $\rightarrow$  TCDB'ye neden olmaz.
- $\log(X_1) = [\log(X_2)]^2 \Rightarrow$  TCDB YOK



\* Not: TCDB varsa değişkenler bağıntılıdır (yani bağımlıdır). Eğer değişkenler birbirine bağlı ise ilişkilidir fakat bunun tersi her zaman doğru değildir.



\* CAR 4 varsayımı bağımsız değişkenler arasındaki bağımlılığı 5  
yani 1'e 1 bir ilişkiyi istemez, Fakat tamdan daha az  
bir ilişkiye izin verir.

• Zaten eğer bağımsız değişkenler arasında bir ilişkiye  
izin verilmezse (ya da yoksa) çoklu doğrusal regresyonun bir anlamı kalmaz  
ve tüm bağımsız değişkenler ayrı ayrı bağımlı değişken üzerine  
regres edilip parametreler hesaplanabilir.

ÖR 2:  $Puan = B_0 + B_1 \text{Harcama} + B_2 \text{Gelir} + u$

Puan = öğrenci başarı puanı

Harcama = öğrenci ailesinin harcaması

Gelir = " " gelir.

Bu regresyonda öğrencinin puanına ailesinin yaptığı harcama  
ve geliri nasıl etki eder bulmaya çalışıyoruz. Modele  
harcamayı koymamızın amacı; harcama ve gelirin ilişkili olduğunu  
biliyoruz ve bu nedenle geliri sabit tutarak harcamanın  
puan üzerindeki yalın etkisini hesaplamaya çalışıyoruz.

\* Özetlemek gerekirse SEKK yönteminin uygulanabilmesi için tek  
sart tam çoklu doğrusal bağımlı olmamasıdır, Fakat bağımsız değişken-  
ler arasında lineer ilişki olabilir.

\* GDB'nin otokorelasyon ve değişen varyans problemlerinden farklı  
anakütlenin değil örneklemin bir sorunu olmasıdır. Bu nedenle  
GDB'nin varlığından ziyade önemi (gücü) anlam kazanır. GDB'nin  
gücündeki artışın nelere sebebiyet verdiği GDB'nin sonuçları  
kısmında incelenecektir.

### GDB'nin Sebepleri

① Veri toplama metodu: bağımsız değişkenlerin dar bir aralıktaki  
değerlerden toplanmış olması.

② Model ya da örneklemdaki kısıtlar:

$$\text{Elektrik Tüketimi} = B_0 + B_1 \text{Gelir} + B_2 \text{Ev Büyüklüğü} + u$$

↑ Otomatikmen bağıllık

③ Fonksiyonel formun yanlış seçilmesi:

$$Y = B_0 + B_1 X_1 + B_2 X_2^2 + u \Rightarrow \text{özellikle } X\text{-ler küçük iken}$$

④ Gereğinden fazla tanımlanan model.

\* Daha önceden belirtildiği gibi GDR4 varsayımı sadece tam GDB'ye izin vermez. Yani bağımsız değişkenler arasında lineer ilişki olabilir fakat modele olan etkisini anlayabilmek için GDB'nin gücü ölçülmelidir.

\* GDB durumunda SEKK parametre tahmincileri hala sapmasız, etkin, doğrusal ve tutarlıdır. Yani hala ÄESTE-dir.

\* Bu durum GDB'nin gücü ne kadar büyük olursa olsun geçerlidir (tam GDB hariç) Doğrusal En iyi Sapmasız Tahmin Edici

\* Peki, GDB'yi biz neden problem olarak görürüz? Bu soruya cevap vermek için 6. denklemdaki modeli ve ona bağlı denklemleri kullanalım

model  $\Rightarrow y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + u_i$  (6)

ÖRF  $\Rightarrow \hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_{i1} + \hat{\beta}_2 X_{i2} + u_i$  (7)

$$\text{Var}(\hat{\beta}_1) = \frac{\sigma^2}{\text{SST}_1(1-R_1^2)}$$

 (9)

$X_{i1} = \delta_0 + \delta_1 X_{i2} + r_{i1}$  (10)

$\hookrightarrow R_1^2 \Rightarrow$  bu modelin belirlilik katsayısı

$\text{SST}_1 = \sum_{i=1}^n (X_{i1} - \bar{X}_1)^2$

•  $X_1$  ve  $X_2$  -nin arasındaki lineer ilişkinin ortaması yani korelasyonun artması  $R_1^2$  -nin artmasına neden olur.

$$\text{Corr}(X_1, X_2)^2 = R_1^2$$

•  $R_1^2 = 1$  tam GDB durumudur ve bu durumda hesap yapılamaz

•  $R_1^2 = 0$  ise basit regresyon durumuna döner. Yani doğru doğrusal regresyona gerek yoktur.

•  $R_1^2$  değeri artmaya başladıkça  $\text{Var}(\hat{\beta}_1)$  değeri artar ve  $R_1^2$  yeteri kadar 1'e yaklaşıncaya sonsuz olur. Kısacası tahmin edilen  $\hat{\beta}_1$  parametre tahmincisinin hassaslığı azalır.

Sonuç: GDB  $\uparrow \Rightarrow R_1^2 \uparrow \Rightarrow \text{Var}(\hat{\beta}_1) \uparrow \Rightarrow$  hassaslık düşü



$\Rightarrow R_1^2$  arttıkça  $\text{Var}(\hat{\beta}_1)$  parabolik olarak artar. 1'e yaklaşmadıkça varsayalım.

$\searrow \text{se}(\hat{\beta}_1) \uparrow$  hassas bir tahmin yapmak zorlaşır.

\*  $se(\hat{\beta}_1) \uparrow$  ise, bu durumdan t-değerleri ve dolayısıyla t-testleri etkilenir.

•  $\beta_1$  için anlamlılık testi yaptığımızı düşünelim

$H_0: \beta_1 = 0$

$H_1: \beta_1 \neq 0$

$t\text{-değeri} = \frac{\hat{\beta}_1 - \beta_1}{se(\hat{\beta}_1)} \Rightarrow t\text{-değeri} = \frac{\hat{\beta}_1}{se(\hat{\beta}_1)}$

$se(\hat{\beta}_1) \uparrow \Rightarrow t\text{-değeri} \downarrow \Rightarrow$


tip II hata  
yani  $\beta$  artar

yanlış olmasına rağmen temel hipotezin yanlış olarak kabulüne daha çok neden olur. Yani red etmeniz gereken  $H_0$  hipotezini red edemez ve  $\beta_1$  i istatistikî olarak anlamsız bulursunuz.

\*  $se(\hat{\beta}_1) \uparrow$  ise, bu durumdan etkilenir. Aralık büyür.

parametre aralık tahmincisi de

$\hat{\beta}_1 - t_{\alpha/2} \cdot se(\hat{\beta}_1) < \beta_1 < \hat{\beta}_1 + t_{\alpha/2} \cdot se(\hat{\beta}_1)$



Aynı sonuç!

• Kısacası, GDB-nin gücü artarsa  $H_0$  hipotezi daha kolay kabul edilir hale gelir

\*  $R^2$  olması gerekenden daha yüksek çıkar. Bağımsız değişkenler arasındaki yüksek lineer ilişki nedeniyle sağ tarafın sol tarafı etkilene gücü gerçek olmayan şekilde artar.

$y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + u_i$

$X_1$  ve  $X_2$ -nin  $Y$  üzerine olan etkisi artmış olarak gözlenir. Fakat bu yanlıştır.

\* Yüksek GDB varlığında F-testi de etkilenir.

• modelin geneli için anlamlılık testi: F-testi

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

$$H_0: \beta_1 = \beta_2 = 0$$

H1: H0 doğru değil

$R^2 \uparrow$  ise  $\rightarrow F \uparrow$

• sonuç: doğru olmamasına rağmen H0 hipotezi yanlış olarak daha sık red edilir. Yani modelin geneli için istatistikî olarak anlamlı sonuç bulunur fakat model gerçekte anlamlı olmayabilir.

\* F-testi ve t-testleri arasındaki tezat sonuca dikkat edilmeli.  
→ önemli  $\Rightarrow$  Neden?

\* Kurulan modeldeki SEKK parametre tahminicileri ve onların varyansları küçük veri değişimlerine karşı çok hassastır. Yani verilerden bir kaçının bile değişmesi sonucu değiştirebilir. Hatta parametre tahminicilerinin işaretleri beklentilerin tersine bile çıkabilir.

\* Genel sonuç  $\Rightarrow$  Yüksek GDB  $\uparrow \Rightarrow R^2 \uparrow \Rightarrow \text{Var}(\hat{\beta}_1) \uparrow \Rightarrow \text{se}(\hat{\beta}_1) \uparrow$

