

Değişen Varyans

* Gauss-Markov varsayımlarından biri hata terimi varyansının sabit olduğunu söylüyordu.

Gökü Doğrusal Regresyon Modeli $\Rightarrow y = B_0 + B_1 X_1 + B_2 X_2 + \dots + B_k X_k + u$

GAR7: Gözlemlenemeyen hata terimi u -nun bağımsız değişkenlere (X) göre koşullu varyansı sabittir.

$$\text{Var}(u | X_1, X_2, \dots, X_k) = \sigma^2$$

$$\text{Var}(u | X) = \sigma^2 \rightarrow X: \{X_1, X_2, \dots, X_k\}$$

* Bu varsayıma göre gözlemlenemeyen hata terimindeki değişkenlik (varyans) açıklayıcı değişkenle (bağımsız değişken) ilişkili olmaz.

* Yukarıda 1 numaralı denklemlerle gösterilen sabit varyans varsayımı altında bağımlı değişkenin koşullu varyansı da sabittir.

$$\text{Var}(y | X_1, X_2, \dots, X_k) = \sigma^2$$

$$\text{Var}(y | X) = \sigma^2$$

* Sabit varyans durumuna "homoskedasticity" de denilmektedir.

* Bu konuda GAR7 sabit varyans varsayımının sağlanmadığı durumda SEKK tahmincilerinin özelliklerini, değişen varyansın nasıl test edileceğini ve düzeltileceğini göreceğiz.

* Fakat değişen varyansı derinlemesine incelemeye önce karşılaştırmaya yapabilmek amacıyla, sabit varyans durumunu grafikte inceleyelim.

* Örnek olarak basit doğrusal regresyon modelinde sabit varyansı ayrıntısıyla inceleyelim.

Model $\rightarrow y = B_0 + B_1 X_1 + u$

GAR1 - GAR4 ✓
 GAR5 $\Rightarrow E(u | X) = 0$ ✓ (sıfır koşullu ort)
 GAR6 $\Rightarrow \text{Corr}(u_i, u_j | X) = 0$ ✓ (otokorelasyon yok)
 GAR7 $\Rightarrow \text{Var}(u | X) = \sigma^2$ ✓ (sabit varyans)

ARF $\rightarrow E[y | X] = B_0 + B_1 X_1$

(3)

$\rightarrow X$ -in lineer bir fonksiyonu yani bağımlı değişkenin ortalaması bağımsız değişkenin değerlerine göre değişiyor.

homoskedastik yani hata terimlerinin varyansı X -lerin değerlerine göre değişmiyor, sabit.

$\text{Var}(y | X) = \sigma^2 \Rightarrow X$ -in lineer bir fonksiyonu değil yani bağımlı değişkenin varyansı bağımsız değişkenin değerlerine göre değişmiyor.

• Hatırlatma

$$\textcircled{1} E(y|X) = E[B_0 + B_1X + u|X]$$

$$= B_0 + B_1X + E[u|X] \xrightarrow{\text{GDR5}} E[u|X] = 0$$

$$= B_0 + B_1X$$

$$\textcircled{2} \text{Var}(y|X) = \text{Var}(B_0 + B_1X + u|X)$$

$$= \text{Var}(u|X)$$

$$= \sigma^2$$

GDR6 $\Rightarrow \text{Corr}(u_i, u_j|X) = 0$
GDR7 $\Rightarrow \text{Var}(u|X) = \sigma^2$

sabit varyans için neden gerekli? Daha sonra göreceğiz!

$$\textcircled{3} \text{Var}(u|X) = \sigma^2$$

Eğer u ve X bağımsız ise

$\text{Var}(u) = \sigma^2$ olarak da yazılabilir.

$$\textcircled{4} \text{Var}(u|X) = \sigma^2$$

$$\text{Var}(u|X) = E[(u - E[u|X])^2 | X]$$

$$= E[u^2 | X]$$

$$\text{Var}(u|X) = E[u^2 | X] = \sigma^2$$

GDR5 $\Rightarrow E[u|X] = 0$

$$\text{Var}(u) = \sigma^2 = E(u^2)$$


$\sigma^2 \Rightarrow$ hata terimi varyansı

$\sigma \Rightarrow$ hata terimi standard sapması

$\hat{\sigma}^2 \Rightarrow$ hata terimi varyans tahmini (Regresyon varyansı)

$\hat{\sigma} \Rightarrow$ hata terimi standard hatası (Regresyon standart hatası)


* Şimdi 3 numaralı denklem ile daha önce tanımladığımız ana kütle regresyon fonksiyonunu (ARF) iki farklı grafikte sabit varyans için göstereyim.



* Yukarıdaki grafikte nokta ile gösterilenler aslında y_i -ler yani gözlemlenmiş bağımlı değişken değerleridir. $\{x_1, x_2\}$, $\{y_1, y_2\}$ ve $\{u_1, u_2\}$ ise birinci ve ikinci gözlem için sırasıyla bağımsız değişken, bağımlı değişken ve hata terimi değerleridir.

* Görüldüğü üzere hem y hem de u -da, x -lerin değerleri artıkça ortalamadan sapmanın değerinde (yani σ) bir değişiklik gözlemlenmemektedir. Kısacası sabit varyans vardır.

* Yukarıdaki grafiği y -nin x -e göre kasıtlı yoğunluk fonksiyonu ile de gösterebiliriz.



* Yoğunluk fonksiyonu y -lerin nerelerde daha çok kümeleştiğini gösteriyor. x_1, x_2, x_3 ise bağımsız değişkenin farklı değerlerini temsil ediyor.

* Görüldüğü üzere y bağımlı değişkeni her bir x değeri için aynı yoğunlukta ARF eğrisi etrafında kümelermiş. Kısacası sabit varyansı işaret ediyor.

* Fakat örnekleme yaptığımız ara kütlenin farklı kesimlerinde varyans değişiyorsa bu varsayım sağlanmaz. Kısacası değişen varyans durumu oluşur.

* Hata teriminin koşullu varyansının değişkenlik göstermesi özellikle yatay-kesit veri analizinde sık rastlanan bir problemdir. Bunun bir sebebi y-nin koşullu dağılımının ara kütlenin farklı kesimlerinde değişkenlik göstermesidir.

↳ Değişen varyans (DV) nereden bir problem olarak görülüyor → Daha önce gördüğümüz üzere DV durumu SEKK parametre tahmincilerinin sapsiz ve tutarlı olmasını engellemez!

Diğer bir ifadeyle SEKK parametre tahmincilerinin varyansı DV durumunda sapsiz olur.

Peki problem NE? SEKK parametre tahmincileri DV durumunda etkin olmaz yani parametre tahmincilerinin varyansları minimum olmaz → olması gereken değerden büyük de olabilir küçük de.

* DV-nin neden olduğu problemleri daha sonra ayrıntısıyla inceleyeceğiz.

* DV-nin var olduğu durumda varyansın gösteriminin nasıl olacağını çoklu doğrusal regresyonu kullanarak inceleyelim.

$$\text{model} \Rightarrow y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + u$$

DV Yoksa (Sabit varyans)

$$\text{Var}(u | x_1, x_2, \dots, x_k) = \sigma^2$$

$$\text{Var}(y | x_1, x_2, \dots, x_k) = \sigma^2$$

ya da

$$\begin{cases} \text{Var}(u | X) = \sigma^2 \\ \text{Var}(y | X) = \sigma^2 \end{cases}$$

$$\text{Bazen indeksle de gösterilir}$$

$$\text{Var}(u_i | X) = \sigma^2$$

$$\text{Var}(y_i | X) = \sigma^2$$

Not:

$$\textcircled{1} X: \{x_1, x_2, x_3, \dots, x_k\}$$

$\textcircled{2}$ $h(x)$ ve h_i bağımsız değişken x-lerin bir fonksiyonudur,

$\textcircled{3}$ $h(x) > 0$ ve $h_i > 0 \Rightarrow$ her X için \Rightarrow neden?

DV Varsa (Değişen varyans)

$$\text{Var}(u | x_1, x_2, \dots, x_k) = \sigma^2 h(x)$$

$$\text{Var}(y | x_1, x_2, \dots, x_k) = \sigma^2 h(x)$$

ya da

$$\begin{cases} \text{Var}(u | X) = \sigma^2 h(x) \\ \text{Var}(y | X) = \sigma^2 h(x) \end{cases}$$

Bazen bu şekillerde de gösterilebilir.

$$\text{Var}(u_i | X_i) = \sigma_i^2$$

$$\text{Var}(y_i | X_i) = \sigma_i^2 h_i$$

* Simdi basit dogrusal regresyonu kullanarak DV durumunu grafik ile incelemeye galsalim. GDR1-GDR4 ✓

model $\Rightarrow y = B_0 + B_1 X + U$

GDR5 $\Rightarrow E(U|X) = 0$ ✓

GDR6 $\Rightarrow \text{Corr}(u_i, u_j|X) = 0$ ✓

GDR7 $\Rightarrow \text{Var}(U|X) = \sigma^2$ ✗

(sifir kosullu ortalama)
(otokorelasyon yok)

$\text{Var}(U|X) = \sigma^2 h(X) \rightarrow$ Değişen varyans

ARF $\Rightarrow E(y|X) = B_0 + B_1 X$

④


X-in lineer bir fonksiyonu yani bağımlı değişkenin ortalaması bağımsız değişkenin değerlerine göre değişiyor

heteroskedastik yani hata terimlerinin varyansı x-lerin değerlerine göre değişiyor, sabit değil

$\text{Var}(y|X) = \sigma^2 h(x) \Rightarrow$ X-in lineer bir fonksiyonu yani bağımlı değişkenin varyansı bağımsız değişkenin değerlerine göre değişiyor.

* Değişen varyans durumuna "heteroskedasticity" de denilmektedir.


* Simdi 4 numaralı denklem ile daha önce tanımladığımız ana kütle regresyon fonksiyonunu (ARF) iki farklı grafikte değişen varyans için göstere lim.



* Yukarıdaki grafikte nokta ile gösterilenler aslında y_i 'ler yani gözlenlediğimiz bağımlı değişken değerleridir. $\{X_1, X_2\}$, $\{y_1, y_2\}$ ve $\{U_1, U_2\}$ ise birinci ve ikinci gözlem için sırasıyla bağımsız değişken, bağımlı değişken ve hata terimi değerleridir.

* Görüldüğü üzere hem y hem de U-da, X-lerin değerleri arttıkça ortalamadan sapmanın değerinde (varyans) bir artış gözlenmektedir. Kısacası değişen varyans vardır.

* Yukarıdaki grafiği Y'nin X-e göre koşullu yoğunluk fonksiyonu ile de gösterebiliriz.



* Yoğunluk fonksiyonu Y-lerin nerelerde daha çok kümeleştiğini gösteriyor. X_1, X_2, X_3 ise bağımsız değişkenin farklı değerlerini temsil ediyor.

* Görüldüğü üzere Y bağımlı değişkeni her bir X değeri için artan yoğunlukta ARF eğrisi etrafında kümelennmiş. Kısacası değişken varyansı işaret ediyor.

ÖRNEK: $maaş = B_0 + B_1 X + u$

DV Yoksa (sabit varyans)

$$\begin{cases} \text{Var}(u | \text{Eğitim}) = \sigma^2 \\ \text{Var}(maaş | \text{Eğitim}) = \sigma^2 \end{cases}$$

→ u ve maaşın varyansı eğitim seviyesine göre değişmiyor.

$$E[maaş | \text{Eğitim}] = B_0 + B_1 \text{Eğitim}$$

→ ortalama maaş eğitim ile değişiyor

* Fakat bu durum gerçekçi olmayabilir.

DV Varsa (Değişen Varyans)

* Daha yüksek eğitim seviyesine sahip kişilerin çok farklı uğraşları ve buna bağlı olarak farklı iş fırsatları olabilir. Bu durum da eğitim seviyesine göre maaşın ortalamadan sapmasını yani varyansın arttırır. Ama düşük eğitimlilerin opsiyonu sınırlıdır ve daha çok asgari ücretli işlerde çalışırlar. Bu da düşük varyans demektir. Kısacası değişen varyans vardır.

$$\begin{aligned} \text{Var}(u | \text{Eğitim}) &= \sigma^2 h(\text{Eğitim}) \\ \text{Var}(maaş | \text{Eğitim}) &= \sigma^2 h(\text{Eğitim}) \end{aligned}$$

Sabit Varyans vs Değişen Varyans Durumunda SEKK Parametre Tahmincileri ve Varyansları

* Şimdi SEKK parametre tahmincilerinin varyanslarını sabit varyans ve değişen varyans durumlarında basit doğrusal regresyonu kullanarak karşılaştıralım.

Basit Doğrusal Regresyon

model $\Rightarrow y = \beta_0 + \beta_1 X + u$

indeks ile model $\Rightarrow y_i = \beta_0 + \beta_1 X_i + u_i$ (5)

daha sonra çoklu doğrusal regresyon içinde gösterileceği için böyle verildi.

CDR1 - CDR4 ✓

CDR5 $\Rightarrow E(u|X) = 0$ ✓

CDR6 $\Rightarrow \text{Corr}(u_i, u_j | X) = 0$ ✓

CDR7 \Rightarrow karşılaştırma durumuna göre değiştireceğiz.

* Karşılaştırmayı basitleştirmek için sadece $\hat{\beta}_1$ ve onun varyansını inceleyelim. Benzer sonuçlar $\hat{\beta}_0$ için de geçerli olacaktır.

$$\hat{\beta}_1 = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sum (x_i - \bar{x})^2} = \frac{\sum (x_i - \bar{x}) y_i}{\sum (x_i - \bar{x})^2} \quad (6)$$

* 5. denklemin 6. denklemden yerine koyalım.

$$\hat{\beta}_1 = \frac{\sum (x_i - \bar{x}) y_i}{\sum (x_i - \bar{x})^2} = \frac{\sum (x_i - \bar{x})(\beta_0 + \beta_1 x_i + u_i)}{\sum (x_i - \bar{x})^2}$$

$$= \frac{\beta_0 \sum (x_i - \bar{x}) + \beta_1 \sum (x_i - \bar{x}) x_i + \sum (x_i - \bar{x}) u_i}{\sum (x_i - \bar{x})^2}$$

$\sum (x_i - \bar{x}) = 0$
 $\sum (x_i - \bar{x}) x_i = \sum (x_i - \bar{x})^2$

$$\hat{\beta}_1 = \beta_1 + \frac{\sum (x_i - \bar{x}) u_i}{\sum (x_i - \bar{x})^2} \quad (7)$$

* 7. denklemin $\hat{\beta}_1$ parametre tahmincisinin x -e göre koşullu olarak beklenen değerini alalım ve $\hat{\beta}_1$ parametre tahmincisinin sapmasız olup olmadığını bulalım.

$$E(\hat{\beta}_1 | X) = E \left[\beta_1 + \frac{\sum (x_i - \bar{x}) u_i}{\sum (x_i - \bar{x})^2} \right]$$

$$= \beta_1 + \frac{\sum [(x_i - \bar{x}) E(u_i | X)]}{\sum (x_i - \bar{x})^2}$$

$$E[\hat{\beta}_1 | X] = \beta_1$$

$\Rightarrow 0 \Rightarrow$ CDR5 $\Rightarrow E(u|X) = 0$
 Kısacası $\hat{\beta}_1$ parametre tahmincisi sapmasızdır. Sapmasızlığı kanıtlarken CDR7 varsayımını kullandık mı?

* Kısacası sabit varyans varsayımı (GDR7) sağlansın ya da sağlanmasın SEKK parametre tahmincileri sapmasızdır. Yani DV sapmasızlığı etkilemez.

* Şimdi de her iki durumda SEKK parametre tahmincilerinin tutarlı olup olmadığına bakalım.

Tutarlılık = $n \rightarrow \infty$ iken parametre tahmincilerinin değeri gerçek parametre değerine yakınsa.

⑧ $\text{plim}_{n \rightarrow \infty} \hat{\beta}_1 = \beta_1$ ise tutarlıdır.

* 7. denklemdeki $\hat{\beta}_1$ parametre tahmincisini kontrol edelim.

$$\text{plim}_{n \rightarrow \infty} \hat{\beta}_1 = \beta_1 + \frac{\sum (x_i - \bar{x}) u_i}{\sum (x_i - \bar{x})^2} = 0$$

$n \uparrow \rightarrow \sum (x_i - \bar{x})^2 \uparrow$

$\text{plim}_{n \rightarrow \infty} \hat{\beta}_1 = \beta_1 \Rightarrow \hat{\beta}_1$ parametre tahmincisi sabit varyans varsayımı olsun ya da olmasın tutarlıdır.

* Kısacası sabit varyans varsayımı (GDR7) sağlansın ya da sağlanmasın SEKK parametre tahmincileri tutarlıdır. Yani DV tutarlılığı etkilemez.

* Şimdi de her iki durumda SEKK parametre tahmincilerinin varyanslarını inceleyip etkin olup olmadıklarına bakalım.

* Önce 7. denklemdeki $\hat{\beta}_1$ parametre tahmincisinin varyansını X -e göre koşullu olarak hesaplayalım.

$$\text{Var}(\hat{\beta}_1 | X) = \text{Var} \left(\beta_1 + \frac{\sum (x_i - \bar{x}) u_i}{\sum (x_i - \bar{x})^2} \mid X \right)$$

$$= \text{Var} \left(\frac{\sum (x_i - \bar{x}) u_i}{\sum (x_i - \bar{x})^2} \mid X \right)$$

$$= \frac{\text{Var} 1}{\left(\sum (x_i - \bar{x})^2 \right)^2} \text{Var} \left(\sum (x_i - \bar{x}) u_i \mid X \right)$$

β_1 sabit parametredir. ve toplam olarak yazılmış bu nedenle varyansı etkilemez

X -e göre koşullu olduğu için X -in fonksiyonu olan $\sum (x_i - \bar{x})^2$ sabit terim görevi görür. Çarpım durumunda olduğu için karesi ile varyans dışına çıkar.

$$\text{Var}(\hat{\beta}_1 | X) = \frac{1}{\left(\sum (x_i - \bar{x})^2\right)^2} \text{Var}\left(\sum (x_i - \bar{x}) u_i | X\right) \quad (9)$$

$$= \frac{1}{\left(\sum (x_i - \bar{x})^2\right)^2} \sum (x_i - \bar{x})^2 \text{Var}(u_i | X)$$

$$= \frac{\sum (x_i - \bar{x})^2 \text{Var}(u_i | X)}{\left(\sum (x_i - \bar{x})^2\right)^2}$$

Bu sadeleştirmeyi yapmak için özel bir varyans kuralı kullanılır.

Kural: Eğer a_i sabit bir sayı ve u_i 'ler ikili olarak ilişkisiz ise yani $\text{Corr}(u_i, u_j) = 0$ ise

$$\text{Var}\left(\sum a_i u_i\right) = \sum a_i^2 \text{Var}(u_i)$$

Dikkat: hata terimleri arasında otokorelasyon olmaması, iste bu noktada devreye giriyor. Varyans formülünün sadeleştirilmesinde ise yarıyor.

Not: formüldeki $a_i = x_i - \bar{x}$

$$\text{Var}(\hat{\beta}_1 | X) = \frac{\sum (x_i - \bar{x})^2 \sigma_i^2}{\left(\sum (x_i - \bar{x})^2\right)^2} \quad (9)$$

* Eğer sabit varyans varsayımı sağlandıysa yani eğer $\text{Var}(u_i | X) = \sigma^2$ ise 9. denklem sadeleştirilebilir.

$$\text{Var}(\hat{\beta}_1 | X) = \frac{\sigma^2 \sum (x_i - \bar{x})^2}{\left(\sum (x_i - \bar{x})^2\right)^2}$$

$$(10) \quad \text{Var}(\hat{\beta}_1) = \frac{\sigma^2}{\sum (x_i - \bar{x})^2} \Rightarrow \text{sabit varyans varsa}$$

* Eğer DV varsa yani eğer olduğu gibi kalır. $\text{Var}(u_i | x_i) = \sigma_i^2$ ise, 9. denklem

$$(11) \quad \text{Var}(\hat{\beta}_1) = \frac{\sum (x_i - \bar{x})^2 \sigma_i^2}{\left(\sum (x_i - \bar{x})^2\right)^2} \Rightarrow \text{Değişen varyans varsa}$$

* Kısacası DV durumunda SEKK parametre tahmincilerinin varyansı minimum değildir, yani varyans ve standard sapmalar sapmalıdır. Bu nedenle parametre tahmincileri etkin değildir, yani en iyi sapmasız parametre tahmincileri değildir. → DESTE değildir.
* Bu nedenle t ve F testleri de artık güvenilirdir değildir.

* Yukarıda basit doğrusal regresyon için yazdığımız varyans denklemlerini (10. ve 11.) şimdi çoklu doğrusal regresyon için de yazalım.

Coklu Doğrusal Regresyon

model $\Rightarrow y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + u$

model indeks ile yazıldı $\Rightarrow y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_k x_{ik} + u$

12

$$\text{Var}(\hat{\beta}_j) = \frac{\sigma^2}{\text{SST}_j(1-R_j^2)} = \frac{\sigma^2}{\text{SSR}_j}$$

\Rightarrow sabit varyans durumu

Hatırlatma: $\bullet \text{SST} = \text{SSE} + \text{SSR}$
 $\bullet R^2 = \frac{\text{SSE}}{\text{SST}}$
 $\bullet \text{SSR} = \text{SST}(1-R^2)$

13

$$\text{Var}(\hat{\beta}_j) = \frac{\sum \hat{r}_{ij}^2 \sigma_i^2}{\text{SSR}_j^2}$$

\Rightarrow değişen varyans durumu

Hatırlatma:

$\bullet \text{SST}_j = \sum (x_{ij} - \bar{x}_j)^2$

$\bullet R_j^2 \Rightarrow X_j$ -yi diğer tüm bağımsız değişkenler üzerine regres ettiğimizde modelin R^2 'si

$\bullet \text{SSR}_j \Rightarrow X_j$ -yi diğer tüm bağımsız değişkenler üzerine regres ettiğimizde modeldeki SSR

$\bullet \hat{r}_{ij} \Rightarrow X_j$ -yi diğer tüm bağımsız değişkenler üzerine regres ettiğimizdeki i . artık.

* Görüldüğü gibi DV olduğunda parametre tahmincilerinin hesaplanması zorlaşıyor.

* Yukarıdaki 10, 11, 12 ve 13 numaralı denklemlerdeki varyans henüz tahmin edilen varyans değil. Eğer tahmin etmek istersek $\hat{\sigma}^2$ ya da \hat{u}_i^2 yi kullanabiliriz.

10' $\text{Var}(\hat{\beta}_1) = \frac{\hat{\sigma}^2}{\sum (x_i - \bar{x})^2}$

11' $\text{Basit Doğrusal Regresyon}$

$$\text{Var}(\hat{\beta}_1) = \frac{\sum (x_i - \bar{x})^2 \hat{u}_i^2}{(\sum (x_i - \bar{x})^2)^2}$$

12' $\text{Var}(\hat{\beta}_j) = \frac{\hat{\sigma}^2}{\text{SSR}_j}$

13' $\text{Coklu Doğrusal Regresyon}$

$$\text{Var}(\hat{\beta}_j) = \frac{\sum \hat{r}_{ij}^2 \hat{u}_i^2}{\text{SSR}_j^2}$$

DV YOK

DV VAR

Değişen Varyansın Soruları

① Parametre tahmin edicileri sapmasızdır. Ayrıca asimptotik olarak da sapmasızdır.

② Parametre tahmin edicileri doğrusaldır.

③ Parametre tahmin edicilerinin varyansları sapsızdır.

④ Bu nedenle parametre tahmin edicileri etkin değildir. Ayrıca asimptotik olarak da etkin değildir. Yani $n \uparrow$ bile (gözlem sayısı artsa) parametre tahmin edicileri yine de etkin olmaz.

Not: Çoklu Doğrusal Bağlantı (CDB) durumunda $n \uparrow$ ise varyans düşer ve parametre tahmin edicileri etkin olmaya yaklaşır. Fakat DV durumunda $n \uparrow$ ile sorun çözülemez.

→ Bu nedenle daha önceden varyansları hesaplamak için kullanılan formüller (örnek: 10 ve 12) ile varyans hesaplandığında bu değerler gerek varyanslardan büyük veya küçük olur.

• Bu durum da güven aralığı tahminlerini, t ve F testlerini etkiler. Geleneksel olarak kullanılan t ve F testleri t ve F dağılımı bile yapmaz, $n \uparrow$ bile.

⑤ Parametre tahmin edicileri hala tutarlıdır.

Sonuç: DV parametre tahmin edicilerinin sapmasız ve tutarlı olması neden olmaz. Fakat etkinlik sağlanamaz.

Değişen Varyansın Nedenleri

* DV daha çok yatay-kesit verilerinde görülür.
* DV daha çok modelin yapısından veya veriden kaynaklanır.

① Model tanımlama hatası (gerekli değişkenin kullanılmaması)

Doğru model $y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \varepsilon$

Kullanılan Model $y = \beta_0 + \beta_1 X_1 + u$

$$u = \beta_2 X_2 + \varepsilon$$

$$\begin{aligned} \text{Var}(u|X_2) &= \text{Var}(\beta_2 X_2 + \varepsilon | X_1) \\ &= \beta_2^2 \text{Var}(X_2|X_1) + \text{Var}(\varepsilon|X_1) \\ &= ? \end{aligned}$$

varyans formülündeki kovaryans terimi nerede?

⇒ kısacası DV olarak X_i 'e bağlı olarak değişecek

Sıfır olur mu? Genellikle hayır.

(2) Katsayıların zamana (zaman serisinde) veya birime (yatay-kesit) göre değişmesidir.

Zaman serisi
Doğru Model $\Rightarrow Y_t = B_0 + B_1 X_{1t} + B_{2t} X_{2t} + \epsilon_t \rightarrow B_2$ zamana göre değişiyor

Kullanılan Model $\Rightarrow Y_t = B_0 + B_1 X_{1t} + B_2 X_{2t} + u_t \rightarrow B_2$ sabit

yani $\left\{ \begin{array}{l} B_{2t} = B_2 + v_t \\ u_t = X_{2t} \cdot v_t + \epsilon_t \end{array} \right.$

$$\text{Var}(u_t | X) = \underbrace{\text{Var}(X_{2t} \cdot v_t | X)}_{\text{genellikle sabit olmaz}} + \text{Var}(\epsilon_t | X)$$

Yatay Kesit
Tüketim = $B_0 + B_1 \text{Gelir} + \epsilon$

• gelir arttıkça marginal tüketim değişecektir

$$\frac{\partial \text{Tüketim}}{\partial \text{Gelir}} = B_1 \Rightarrow \text{genelde sabit değildir.}$$

Bu nedenle kukla değişken kullanarak veriyi homojen alt gruba bölebiliriz.

(3) Veri toplamasında yapılan hatalar.

(4) Bağımlı değişkende yapılan ölçme hataları.