

Değişen Varyansın Düzeltilmesi

* Uyguladığımız DV testleri sonucunda modelde istatistikî olarak DV olduğu sonucuna varırsak, DV-nin düzeltilmesi ve modelin buna uygun olarak yeniden tahmin edilmesi gerekir.

* DV-nin düzeltilmesi için literatürde sıklıkla kullanılan 4 adet yöntem vardır: Logaritmik transformasyon, DV Dirençli (Gürbüz) Standart Hata kullanımı, Ağırlıklandırılmış En Küçük Kareler (Weighted Least Squares - WLS) kullanımı, Tahmin Edilebilir Genelleştirilmiş En Küçük Kareler (Feasible Generalized Least Squares - FGLS) kullanımı.

* Bu yöntemler içinde en basiti logaritmik transformasyondur. Fakat en sık kullanılan dirençli standart hataların kullanımıdır.

① Logaritmik Transformasyon

* DV-nin modelde olması durumunda ilk uygulanabilir olarak yöntem tüm değişkenlerin logaritmasını (doğal logaritma) almaktır.

$$\text{ana model} \rightarrow y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \epsilon$$

$$\text{logaritmik model} \rightarrow \ln y = \alpha_0 + \alpha_1 \ln X_1 + \alpha_2 \ln X_2 + u$$

logaritmik transformasyon

* Logaritmik transformasyon değişkenleri yeniden ölçeklendirdiği yeni ölçek küçülttüğü için dönüşüm yapılmış modelde DV olmayabilir.

* Logaritmik transformasyon varyansı stabilize eder.

$$\text{Not: } \ln(x) = 1 \rightarrow x = e^1$$

$$\ln(2) = x \rightarrow 2 = e^x$$

ÖRNEK Şimdi bir çoklu doğrusal regresyon modeli üzerinden logaritmik transformasyonun DV-yi ortadan kaldırıp kaldırmadığına bakalım. Düzey formundaki ana modeli öncelikle Breusch Pagan testi ile DV için test edeceğiz daha sonra ana modeli logaritmik transformasyon ile tekrar hesaplayıp White testin ikinci versiyonu ile DV için test edeceğiz.

ana model $\rightarrow y = B_0 + B_1 X_1 + B_2 X_2 + B_3 X_3 + u$

ÖRF $\rightarrow \hat{y} = -21,77 + 0,0021 X_1 + 0,123 X_2 + 13,853 X_3$
(29.475) (0,006) (0,013) (9.010)

$n = 88 \quad R^2 = 0,672$

Breusch-Pagan test ile DV varlığını araştırıyoruz. Yani yukarıda uyguladığımız modelden kalıntıları çekip $(y_i - \hat{y}_i = \hat{u}_i)$ onların korelasyonunu alıp tüm bağımsız değişkenler üzerine regres ediyoruz.

$\hat{u}^2 = -5522,79 + 0,202 X_1 + 1,691 X_2 + 1041,76 X_3$
(3259,5) (0,071) (1,464) (996,38)

→ yardımcı regresyon ÖRF

$n = 88 \quad R^2 = 0,1601$

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

Yardımcı regresyonda daha önceden gösterdiğimiz F yada LM testini uyguladığımızda $F = 5,34$ ve $LM = 14,09$ buluyoruz. Sadere F testi üzerinden gittiğimizde %5 anlamlılık düzeyinde $F_{\alpha, k, n-k-1} = 2,71 \leftarrow F\text{-kritik değeri}$.

Sonuç olarak H_0 temel hipotezini red edip DV buluyoruz.

* Şimdi ana modeli logaritmik transformasyona uğratalım ve bu modelde DV varlığını white testin ikinci versiyonu ile test etmeye çalışalım.

logaritmik model $\rightarrow \ln y = \alpha_0 + \alpha_1 X_1 + \alpha_2 X_2 + \alpha_3 X_3 + \epsilon$

ÖRF $\rightarrow \hat{\ln y} = -1,30 + 0,17 \ln X_1 + 0,7 \ln X_2 + 0,04 \ln X_3$
(0,651) (0,038) (0,093) (0,028)

$n = 88 \quad R^2 = 0,643$

White testin ikinci versiyonu ile DV varlığını araştırıyoruz. Yani yukarıda uyguladığımız logaritmik modelden kalıntıları çekip $(\ln y_i - \ln \hat{y}_i = \hat{\epsilon}_i)$ onların korelasyonunu alıp \hat{y} ve \hat{y}^2 (yani $\hat{\ln y}$ ve $\hat{\ln y}^2$) üzerine regres ediyoruz.

doğal logaritmasını aldığımız için $\ln y$ kullanmamızdır.

yardımcı regresyon → $\hat{\varepsilon} = 5.047 - 1.709 \ln \hat{y} + 0.145 \ln \hat{y}^2$
 ÖRF (3.345) (1.163) (0.100)

$n=88$ $R^2=0.03917$

$LM = n \cdot R^2$

• Yardımcı regresyonda daha önceden gösterdiğimiz F ya da LM testini uyguladığımızda $LM = 3.447$ ve $F = 1.7325$ buluyoruz. Sadece LM testi üzerinden gittiğimizde %5 anlamlılık düzeyinde $\chi^2_{\alpha, k} = 5.99$ ← LM testi için kritik değer.

• Sonuç olarak H_0 temel hipotezini red edemiyoruz ve sabit varyans kararı veriyoruz.

* Görüldüğü üzere logaritmik transformasyon modeldeki DV-nin düzeltilmesini sağlamış oldu.

② DV Dirençli (Gürbüz) Standart Hata Kullanımı

* Yatay kesit verisi ile yapılan regresyonlarda değişen varyans varlığında takip edilebilen bir diğer yol ise DV Dirençli (Gürbüz) Standart Hatalarının kullanılmasıdır.

* DV Dirençli (Gürbüz) Standart hataları → dirençli standart hataları
 → Heteroskedasticity-robust-standard error → White Standart hataları

* Değişen varyansın bilinmeyen bir formu mevcut iken yani $Var(u|x) = \sigma^2 h(x)$ ve $h(x)$ fonksiyonunun formu bilinmiyorken dirençli standart hataları kullanarak daha önceden geçersiz olan t ve F testlerini artık geçerli hale getirmek mümkün olacaktır.

↳ Not! DV durumunda SEKK parametre tahmincileri için hesapladığımız varyans formülleri geçersiz olacağı için t ve F testleri de geçersiz olacaktır. Bu konuyu daha önce ayrıntısı ile görmüştük.

↳ Kısacası DV durumunda dirençli standart hataları kullanarak DV-den etkilenmeyen t ve F istatistikleri (hatta LM istatistiği) hesaplamak mümkün olacaktır.

* Dirençli standart hatalar modelde DV olsun ya da olmasın her iki durumda da geçerlidir. Yani t ve F testleri güvenilirdir.

↳ Peki neden her zaman dirençli standart hataları kullanmıyoruz?

• Eğer DV yoksa ve artıklar normal dağılıyorsa, t istatistiği gözlem sayısına bakılmaksızın tam t dağılımı yapar.

• Dirençli standart hata kullanılarak elde edilen t-istatistiğinin t dağılımı yapabilmesi gözlem sayısının yeterince büyük olmasına bağlıdır.

- Kısacası dengeli standart hata kullanımı sadece büyük örneklem durumunda geçerlidir.
- Küçük örneklerde ise değişen varyansın yapısına (formuna) ilişkin belirli varsayımlar altında SEKK dışında daha etkin bir tahmin yönteminin (WLS ya da FGLS) kullanılması gerekir. Çünkü SEKK artık DESTE değildir.

→ Ayrıca unutulmamalıdır ki DV durumunda parametre tahmincilerinin güven aralıkları da geçersiz oluyordu. DV durumunda dengeli standart hataları kullanarak geçerli güven aralıkları elde edebiliriz. Tek yapmamız gereken güven aralığı formülünde bahse konu olan parametre tahmincisinin normal standart hatasını kullanmak yerine aynı parametre tahmincisine ait dengeli standart hatayı kullanmaktır.

* Şimdi dengeli standart hataların ve ona bağlı t, F ve LM istatistiklerinin basit ve çoklu doğrusal regresyon için ayrı ayrı göstereyim.

Basit Doğrusal Regresyon

Çoklu Doğrusal Regresyon

① model $\rightarrow y = \beta_0 + \beta_1 X + u \rightarrow$ DV varsayımı hariçinde tüm varsayımlar geçerli

model $\rightarrow y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + u$

③
$$\text{Var}(\hat{\beta}_1) = \frac{\sigma^2}{\sum (x_i - \bar{x})^2}$$

Sabit varyans varken

④
$$\text{Var}(\hat{\beta}_j) = \frac{\sigma^2}{SST_j(1-R_j^2)} = \frac{\sigma^2}{SSR_j}$$

⑤
$$\begin{aligned} \text{Var}(\hat{\beta}_1) &= \frac{\sum (x_i - \bar{x})^2 \sigma_i^2}{(\sum (x_i - \bar{x})^2)^2} \\ &= \frac{\sum (x_i - \bar{x})^2 \hat{\sigma}_i^2}{SST_x^2} \end{aligned}$$

Değişen varyans varken

⑥
$$\text{Var}(\hat{\beta}_j) = \frac{\sum \hat{\sigma}_i^2}{SSR_j^2}$$

Dikkat: 3., 4., 5. ve 6. denklemlerdeki varyanslar herüç tahmin değil. Ekonometri I dersinden hatırlayın ki parametre tahmincilerinin varyansını tahmin edebilmek için öncelikle $\hat{\sigma}^2$ -yi (ya da DV durumunda $\hat{\sigma}_i^2$ -yi) tahmin etmeli ve yukarıdaki formüllerde σ^2 yerine (ya da DV durumunda $\hat{\sigma}_i^2$ yerine) koymalıyız. Bu durumda varyansları tahmin etmiş oluruz.

Not: $SST_x = \sum (x_i - \bar{x})^2$

* Simdi DV durumunda formülünü elde ettigimiz varyans denklemlerini (5. ve 6. denklem) tahmin etmeye bakalim.

* White (1980), 5. ve 6. denklemlerdeki varyansların ara modeldeki artıkları (\hat{u}) kullanarak tahmin edilebileceğini gösterdi.

* Aşağıdaki 7. ve 8. varyans tahmin formülleri hem sabit varyans hem de değişen varyans durumunda geçerli dirençli varyanslardır.

Basit Doğrusal Regresyon

Çoklu Doğrusal Regresyon

(7)
$$Var(\hat{\beta}_1) = \frac{\sum (x_i - \bar{x})^2 \hat{u}_i^2}{SST_x^2}$$

(8)
$$Var(\hat{\beta}_j) = \frac{\sum \hat{r}_{ij}^2 \hat{u}_i^2}{SSR_j^2}$$

Not: 7. ve 8. denklemlerdeki varyansların tahmin olduğunu unutmayın.

Dirençli Varyans ?!

(9)
$$se(\hat{\beta}_1) = \sqrt{Var(\hat{\beta}_1)}$$

(10)
$$se(\hat{\beta}_j) = \sqrt{Var(\hat{\beta}_j)}$$

Dirençli Standart Hatalar

* Dirençli standart hataları elde ettikten sonra dirençli t-istatistiğini elde etmek çok kolay olacaktır.

$$t = \frac{\text{tahmin} - \text{hipotez değeri}}{\text{dirençli standart hata}} = \frac{\hat{\beta}_j - \beta_j}{se(\hat{\beta}_j)}$$

• Yani tek yapmamız gereken daha önceden bildiğimiz t-istatistiği formülünde yeni hesaplanan dirençli standart hataları kullanmaktır (normal standart hata yerine).

ÖR: model $\rightarrow y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + u$
ÖRF $\rightarrow \hat{y} = 0.321 + 0.213 x_1 - 0.198 x_2$

Dirençli standart hatalar normal standart hatalara göre bazen büyük bazen küçük çıkıyor!

(0.100)	(0.055)	(0.058)	Normal standart hatalar
[0.109]	[0.053]	[0.058]	

Dirençli standart hatalar (köşeli parantez ile verildi)

Not: DV durumunda, t-istatistiği ve güven oranlığı hesaplamasında dirençli standart hatalar kullanılmalıdır.

* Direnali t-istatistikleri elde ettiğimiz gibi direnali F-istatistigi ve LM-istatistigi de mümkündür.

* Fakat direnali F-istatistiginin kapalı bir formu (belirli bir formu-formülü) yoktur. Bu nedenle elle aözmek zordur. Zaten bir çok istatistik programında direnali standart hataları ve istatistikleri elde etmek için özel paketler olduğundan, araştırmacılar bu değerleri genellikle kendileri elle hesaplamazlar.

* Direnali F-istatistiginin aksine direnali LM-istatistiginin bulunması biraz daha fazla uğrasla mümkündür.

Direnali Wald istatistigi de derin! matrikslerle yapılır.

Not: LM testi aynen F testinin test ettiği durumlarda (modelin genelinin testi ya da çoklu kısıtların testi gibi) uygulanabilir.

* DV durumunda direnali LM-istatistigini hesaplamak için aşağıdaki ana modeli düşünelim.

n = gözlem sayısı

(11) ana model $\rightarrow y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + u$

• ve test etmek istediğimiz hipotez ise $H_0: \beta_1 = \beta_2 = 0$ olsun \rightarrow **q = kısıt sayısı**

• Eğer DV olmasaydı yukarıdaki hipotez LM testi ile şu aşamalarla test edilirdi:

1) Temel hipoteze göre olan kısıtlanmış modeli tahmin edin (yeri yukarıda örnek olarak verilen hipotezdeki kısıtları modele uygulayın)

$\rightarrow y = \delta_0 + \delta_1 X_3 + \varepsilon \rightarrow \hat{\varepsilon}$ topla

2) Kısıtlanmış modeldeki artıkları ($\hat{\varepsilon}$) toplayın.

3) $\hat{\varepsilon}$ -leri tüm bağımsız değişkenler (kısıtlanmış olsun ya da olmasın) üzerine regres et.

$\hat{\varepsilon} = \alpha_0 + \alpha_1 X_1 + \alpha_2 X_2 + \alpha_3 X_3 + v \rightarrow R^2_{\hat{\varepsilon}}$ hesapla

$LM = n R^2_{\hat{\varepsilon}} \rightarrow \chi^2_q \Rightarrow$ ki-kare dağılımı yapar

$\alpha = anlamlılık$ seviyesinde eğer $LM-ist > \chi^2_{\alpha, q}$ (kritik değer) } H_0 red edilir ve model istatistiki olarak anlamlı sonucuna varılır.

Fakat modelde DV varsa, biraz daha uğrasla,
11. denklemde verilen model 12. denklemde verilen hipotez için LM testi ile (direnali LM testi) test edilebilir.

1) Temel hipoteze göre olan kısıtlanmış modeli tahmin edin (yani 12. denklemde verilen hipotezdeki kısıtları modele uygulayın)

kısıtlanmış model $\rightarrow y = \delta_0 + \delta_1 X_3 + \varepsilon \rightarrow \hat{\varepsilon}$ topla

2) Kısıtlanmış modeldeki artıkları ($\hat{\varepsilon}$) toplayın.

3) Temel hipotezdeki kısıtlara dahil olan tüm bağımsız değişkenleri ayrı ayrı kısıtı olmayan tüm değişkenler üzerine regres edin ve artıkları toplayın.

$X_1 = \alpha_0 + \alpha_1 X_3 + \Gamma_1 \rightarrow \hat{\Gamma}_1$ topla

$X_2 = \gamma_0 + \gamma_1 X_3 + \Gamma_2 \rightarrow \hat{\Gamma}_2$ topla

4) 3. adımda elde ettiğiniz artıkları, 1. aşamadaki artıkları karşılaştıran yeni değişkenler oluştur ve bunları tüm değişkenler üzerine regres et.

Dikkat \rightarrow Sabit terim yok $\rightarrow 1 = \theta_1 \hat{\Gamma}_1 \hat{\varepsilon} + \theta_2 \hat{\Gamma}_2 \hat{\varepsilon} \Rightarrow SSR$ topla $\Rightarrow SSR_1$ diye tanımlayalım

$LM = n - SSR_1 \rightarrow \chi^2_q \Rightarrow$ ki-kare dağılımı yapar

$\alpha =$ anlamlılık seviyesinde eğer $LM-ist > \chi^2_{\alpha,q}$ (kritik değer)

H_0 red edilir ve model istatistik olarak anlamlı sonucuna varılır.

Direnali LM istatistiği

n büyük olduğu sürece DV olsun ya da olmasın geçerlidir!

Not: n = gözlem sayısı ; q = kısıt sayısı

③ Ağırlıklandırılmış En Küçük Kareler Yöntemi (WLS) [8]

* Weighted Least Squares (WLS) yöntemi olarak da bilinmektedir.

* Bazen dirençli standart hataları kullanmak yerine modeli değişen varyansın arındırılarak yeniden tahmin etmek isteyebiliriz. Bunun için SEKK değil de WLS yöntemini kullanabiliriz.

* DV durumunda WLS, SEKK'den daha etkin parametre tahminçileri sunar. Yani artık parametre tahminçileri sopsanız ve tutarlı olmalarını yanı sıra etkin de olurlar. Kısacası parametre tahminçileri DESTE olur.

↳ WLS-de t ve F istatistikleri geçerlidir yani t ve F istatistikleri tam olarak t ve F dağılımı yapar.

* WLS yöntemi değişen varyans formuna ilişkin bilgiyi gerektirir. Yani değişen varyansı oluşturan fonksiyonun tam olarak bilinmesi gerekir.

* Örnek olarak aşağıdaki ağırlıklı doğrusal regresyonu ele alalım.

⑬ ana model $\rightarrow y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + u$ \rightarrow GDR1-6 \rightarrow GDR7 X

• sadece GDR7 varsayımının (DV yok) sağlanmadığını ve DV'nin formunun aşağıdaki gibi olduğunu düşünelim

$$\text{Var}(u_i | x_i) = \sigma^2 h(x) = \sigma^2 h_i$$

• Burada $h(x) > 0$ x'lerin herhangi bir fonksiyonudur. \rightarrow Neden her zaman sıfırdan büyük olmalı?

• $h(x)$ -in bilindiğini düşünelim. \Rightarrow yani tüm h_i 'ler

• Şimdi, 13. denklemden verilen ana modeli belli bir değer kullanarak dönüştüreceğiz ve sonra olarak dönüşüme uğrayan bu yeni model GDR1-GDR6 varsayımlarını sağlamanın yanı sıra GDR7 (DV YOK) varsayımını da sağlar.

• Dönüşüm için hangi değeri kullanalım?

↳ DV-ye neden olan $h(x)$ fonksiyonunun kare kökünü kullanmayı deneyelim ve sabit varyansa ulaşmış olsamıza bakalım.

* Dönüşümü $\sqrt{h(x)}$ terimi ile yapıyoruz yani model de her g gördüğümüz değişken (hata terimi de dahil) $\sqrt{h(x)}$ -e böleceğiz. Bu işlemi her gözlem için yapacağımızdan indeksli olan versiyonu yani $\sqrt{h_i}$ 'yi kullanalım.

* Dönüşüme uğramış u_i -leri tanımlayalım ve beklenen değer ve varyanslarını inceleyelim.

$$u_i^* = \frac{u_i}{\sqrt{h_i}}$$

dönüştürülmüş hata terimi

$$E[u_i^* | X] = E\left[\frac{u_i}{\sqrt{h_i}} \mid X\right]$$

$$= \frac{1}{\sqrt{h_i}} E[u_i | X]$$

$$= 0 \rightarrow \text{CRR5}$$

Dönüştürülmemiş modelde

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

$$= E\left[\left(\frac{u_i}{\sqrt{h_i}}\right)^2 \mid X\right]$$

$$= \left(\frac{1}{\sqrt{h_i}}\right)^2 E[u_i^2 | X] = \frac{1}{h_i} \sigma^2 h_i = \sigma^2 \Rightarrow \text{sabit varyans elde edildi}$$

yani CDR7 sağlanmış oldu.

* Modeldeki varsayımlar sağlandığına göre artık 13. denklemden verilen ana modeli $\sqrt{h_i}$ ile dönüştürebiliriz.

ana model $\rightarrow y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_k X_{ik} + u_i$

indeks ile yazıldı

dönüştürülmüş model $\rightarrow \frac{y_i}{\sqrt{h_i}} = \beta_0 \frac{1}{\sqrt{h_i}} + \beta_1 \frac{X_{i1}}{\sqrt{h_i}} + \beta_2 \frac{X_{i2}}{\sqrt{h_i}} + \dots + \beta_k \frac{X_{ik}}{\sqrt{h_i}} + \frac{u_i}{\sqrt{h_i}}$

(14) yeni model $\rightarrow y_i^* = \beta_0 x_{i0}^* + \beta_1 x_{i1}^* + \beta_2 x_{i2}^* + \dots + \beta_k x_{ik}^* + u_i^*$

$x_{i0}^* = \frac{1}{\sqrt{h_i}}$; $\text{Var}(u_i^* | X) = \sigma^2$; $E(u_i^* | X) = 0$

* 14. denklemden verilen yeni model tüm Gauss-Markov varsayımlarını sağlar. Parametre tahminicileri \rightarrow DESTER ✓

$\hat{\beta}_0^*, \hat{\beta}_1^*, \hat{\beta}_2^*, \dots, \hat{\beta}_k^*$ \rightarrow karışıklık olmaması için "*" ile belirtildi.

* Burada dikkat edilmesi gereken parametre tahmincilerinin yorumlanması 13. denklem üzerinden yapılırken. Bu tahminciler için t ve F testlerini uygulamak için ise 14. modeldeki sonuçlar kullanılır. → Çünkü bunlar geçerli t ve F istatistikleridir.

* Diğer bir önemli nokta ise 14. denklemden (dönüştürülmüş) elde edilen parametre tahmincileri $\{\hat{\beta}_0^*, \hat{\beta}_1^*, \hat{\beta}_2^*, \dots, \hat{\beta}_k^*\}$, 13. denklemden elde edilen parametre tahmincilerinden $\{\hat{\beta}_0, \hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_k\}$ farklıdır.

* Not: 14. denklemdeki gibi dönüştürülmüş bir modele SEKK yöntemi uygulanırsa buna genel olarak Genelleştirilmiş En Küçük Kareler (Generalized Least Squares - GLS) yöntemi denir. Eğer GLS, değişen varyans amacıyla yapılırsa buna da WLS denir.

* Bu nedenle $\{\hat{\beta}_0^*, \hat{\beta}_1^*, \hat{\beta}_2^*, \dots, \hat{\beta}_k^*\}$ parametre tahmincilerine bazen GLS tahmincileri de denilmektedir.

* GLS parametre tahmincileri DESTE özelliklerini sağlar. Ayrıca doğru standart hatalara sahip oldukları için t ve F istatistikleri geçerlidir.

* WLS-deki temel fikir hata varyansı büyük olan gözleme daha az ağırlık $\left(\frac{1}{\sqrt{h_i}}\right)$ verilmesi ve hata varyansı küçük olan gözleme daha fazla ağırlık verilmesidir. Böylelikle her gözlem için hata varyansı eşitlenebilir.

* SEKK-de ise her zaman her gözleme eşit ağırlık verilir. → Ağırlık her gözlem için 1'dir.

* Ağırlıklandırmayı daha iyi anlayabilmek için çoklu doğrusal regresyonda parametre tahmincilerini hesaplamak için kullandığımız amaç fonksiyonunu hatırlayalım. (13. denklemdeki model için)

$$\rightarrow \min \sum_{i=1}^n \hat{u}_i^2 = \sum_{i=1}^n \frac{1}{1} (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_{i1} - \hat{\beta}_2 x_{i2} - \dots - \hat{\beta}_k x_{ik})^2$$

• Bu amaç fonksiyonunu 14. denklemden belirtilen dönüştürülmüş model için yazalım

$$\min \sum_{i=1}^n \left(\frac{\hat{u}_i}{\sqrt{h_i}}\right)^2 = \sum_{i=1}^n \left(\frac{y_i}{\sqrt{h_i}} - \frac{\hat{\beta}_0}{\sqrt{h_i}} - \frac{\hat{\beta}_1 x_{i1}}{\sqrt{h_i}} - \frac{\hat{\beta}_2 x_{i2}}{\sqrt{h_i}} - \dots - \frac{\hat{\beta}_k x_{ik}}{\sqrt{h_i}}\right)^2$$

$$(16) \min \sum_{i=1}^n \frac{1}{h_i} \hat{u}_i^2 = \sum_{i=1}^n \frac{1}{h_i} (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_{i1} - \hat{\beta}_2 x_{i2} - \dots - \hat{\beta}_k x_{ik})^2$$

amacımız artıkların karesini minimize etmek

çünkü $h_i \rightarrow x$ -e göre artan bir fonksiyon

* 16. denklemler görüldüğü gibi WLS amaç fonksiyonunu h_i ile ağırlıklandırıyor. Daha önce gösterdiğimiz hata terimi varyansın formunu hatırlayın: 11

$$\text{Var}(u_i | X_i) = \sigma^2 h_i \rightarrow \text{yani } \frac{1}{h_i} \text{ amaç fonksiyonu}$$

ile ağırlıklandırılırken
aslında tüm değişkenler
 h_i 'nin kare kökü ($1/\sqrt{h_i}$) ile
ağırlıklandırılmış.

* 15. denklemler de SEKK'nin tüm değişkenleri eşit (1 ile) ağırlıklandırıldığı görülüyor. Bu yönüyle aslında SEKK, WLS'nin özel bir halidir.

Not: Dönüştürülmüş modelin (14. denklem ile verilmiş WLS) R^2 -si uyum iyiliği ölçütü için kullanılamaz. Ancak test istatistiklerinin hesaplanmasında kullanılabilir.

Not: WLS yöntemini kullanabilmek için DV'nin formunun yani örneğimizdeki h_i 'nin fonksiyonel formunun bilinmesi gerekir. Eğer bilinmiyorsa FGLS kullanılmalıdır.

Tahmin Edilebilir Genelleştirilmiş En Küçük Kareler Yöntemi (FGLS)

* Uygulamada değişen varyansın fonksiyonel formu (yani h_i 'nin fonksiyonel formu) genellikle bilinmez.

* Bu durumda değişen varyans yapısının (yani h_i) eldeki verilerle tahmin edilmesi gerekir.

* DV'nin formunun tahmin edilerek değişkenlerin aynı WLS'deki gibi ağırlıklandırılması yöntemine FGLS yöntemi denir.

* $\text{Var}(u_i | X_i) = \sigma^2 h_i \rightarrow$ bilinmez ve data ile tahmin edilir
yani h_i yerine \hat{h}_i kullanılarak
ağırlıklandırma yapılırken.

* FGLS-de oldukça genel bir sergüze sunan varyans formunu aşağıdaki gibidir

$$(17) \text{Var}(u | X) = \sigma^2 \exp(\delta_0 + \delta_1 X_1 + \delta_2 X_2 + \dots + \delta_k X_k)$$

$h(x)$

$$h(x) = \exp(\delta_0 + \delta_1 X_1 + \delta_2 X_2 + \dots + \delta_k X_k)$$

* Not: $h(x)$ formunda exponansiyonel fonksiyon kullanılmıştır
 Çünkü varyansın her zaman pozitif ya da en azından sıfır
 olmasıdır. Fakat doğrusal modellerde tahmin edilen değerlerin
 (bizim örneğimizde \hat{h}_i) negatif değerler almaması garanti
 değildir. Exponansiyonel fonksiyon kullanılarak negatif değerler
 almaması garanti edilmiş olur.

* $h(x) = \exp(\delta_0 + \delta_1 x_1 + \delta_2 x_2 + \dots + \delta_k x_k)$

↓ Burada δ_j parametrelerini bilmediğimiz için
 $h(x)$ tahmin etmeye çalışıyoruz. Eğer bilseydik
 direkt olarak WLS uygulayabilirdik. Bu paramet-
 releri bilmediğimiz için önce δ_j -leri tahmin
 edeceğiz daha sonra h_i -yi tahmin edeceğiz yani
 \hat{h}_i -yi bulacağız.

* 17. denklemden verilen varyans formunu, varyansın temsilcisi olan
 u^2 -yi kullanarak yeniden yazalım.

$Var(u|x) = \sigma^2 \exp(\delta_0 + \delta_1 x_1 + \delta_2 x_2 + \dots + \delta_k x_k)$
 $h(x)$

↓ $u^2 = \sigma^2 \exp(\delta_0 + \delta_1 x_1 + \delta_2 x_2 + \dots + \delta_k x_k) \cdot v$ → x -lere göre ortalama'sı 1 olan terim eklendi

↓ doğal logaritmasını al

$\ln u^2 = \ln \sigma^2 + \delta_0 + \delta_1 x_1 + \delta_2 x_2 + \dots + \delta_k x_k + \ln v$
 $= \delta_0$ $= \epsilon$

$\ln u^2 = \delta_0 + \delta_1 x_1 + \delta_2 x_2 + \dots + \delta_k x_k + \epsilon$

ana modelden elde edilen \hat{u}^2 kullanılarak u^2 -nin temsilcisi olarak

$\ln \hat{u}^2 = \delta_0 + \delta_1 x_1 + \delta_2 x_2 + \dots + \delta_k x_k + \epsilon$ (18)

↓ \hat{h}_i -yi bulabilmek için tahmin etmemiz gereken model budur. 18. modeli tahmin edip bağımlı değişkenin tahmin edilen değerlerini yani $\ln \hat{u}_i^2$ -yi hesaplamamız gerekir. Daha sonra bu değerlerin exponansiyel fonksiyonunu alırsak \hat{h}_i -yi elde ederiz.

(19) $\hat{h}_i = \exp(\ln \hat{u}_i^2)$

* \hat{h}_i 'leri hesapladıktan sonra aynı WLS-de uyguladığımız 13 prosedürleri bu sefer \hat{h}_i 'leri kullanarak uygulayabiliriz.

↳ Yani tüm değişkenleri ağırlıklandırmak için $\frac{1}{\sqrt{\hat{h}_i}}$ ağırlıklarını kullanacağız ya da

amaa fonksiyonunu $\frac{1}{\hat{h}_i}$ ile ağırlıklandıracağız.

* \hat{h}_i 'ler yerine WLS-deki gibi h_i 'leri kullanabilseydik parametre tahmincileri sapmasız olacaktı. Fakat FGLS-de hem modeli hem de \hat{h}_i 'leri aynı datayı kullanarak tahmin ettiğimiz için parametre tahmincileri artık sapmalı olur. Buna rağmen FGLS-deki parametre tahmincileri hala tutardır ve SEKK'ye göre asimptotik olarak daha etkindir.

↳ FGLS-de parametre tahmincileri **sapmalı** olduğu için parametre tahmincileri artık **DESTE** değildir.

↳ Fakat DV durumunda ve gözlem sayısı yeterince büyükse SEKK yöntemine iyi bir alternatiftir.

↳ FGLS-de $n \uparrow$ ise t ve F istatistikleri tam olarak t ve F dağılımı yapar.

Not: Bu konuda DV-yi düzeltmek için 4 farklı yöntem gördük. Uygulamada en sık kullanılan yöntem dirençli standart hataların kullanılmasıdır.